

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁŘSKÁ PRÁCE



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

**SEGMENTACE BUNĚK POMOCÍ KLASIFIKACE PIXELŮ VE
SNÍMCÍCH Z RŮZNÝCH MIKROSKOPICKÝCH MODALIT**

CELL SEGMENTATION BY PIXEL CLASSIFICATION IN IMAGES FROM VARIOUS MICROSCOPIC
MODALITIES

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Jan Vývoda

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Tomáš Vičar

BRNO 2020

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Student: Jan Vývoda

ID: 203692

Ročník: 3

Akademický rok: 2019/20

NÁZEV TÉMATU:

Segmentace buněk pomocí klasifikace pixelů ve snímcích z různých mikroskopických modalit

POKYNY PRO VYPRACOVÁNÍ:

1) Prostřednictvím odborné literatury se seznámte s metodami pro segmentaci pomocí klasifikace jednotlivých pixelů. 2) Proveďte literární rešerši se zaměřením na vhodné klasifikátory a příznaky používané v těchto metodách. 3) Na základě literární rešerše vyberte nejvhodnější příznaky pro aplikaci na mikroskopické snímky buněk a ve zvoleném programovacím prostředí realizujte extrakci těchto příznaků. 4) Vhodnost použitých příznaků statisticky vyhodnoťte na snímcích jedné z mikroskopických modalit. 5) Na vybraný soubor příznaků aplikujte vybrané klasifikátory. 6) Otestujte výsledky různých příznaků a klasifikátorů pro snímky buněk z různých mikroskopických modalit. 7) Proveďte diskusi dosažených výsledků a zhodnoťte účinnost a využitelnost různých klasifikátorů a příznaků pro různé modalit.

DOPORUČENÁ LITERATURA:

[1] BANKMAN, Isaac N. Handbook of Medical Image Processing and Analysis. Two dimensional shape and texture quantification. 2nd ed. San Diego: Academic Press, 2009, s. 261-277. ISBN 978-0-12-373904-9.

[2] DUDA, O. R., et al. Pattern Classification. New York: Wiley, 2001, ISBN 0471056693.

Termín zadání: 3.2.2020

Termín odevzdání: 5.6.2020

Vedoucí práce: Ing. Tomáš Vičar

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato bakalářská práce se zabývá problematikou segmentace buněk pomocí klasifikace pixelů ve snímcích z různých mikroskopických modalit. Jsou zde shrnuty možnosti vytvoření příznaků, zmíněné klasifikátory vhodné pro tento druh segmentace a následně v praktické části vypracované výsledky pro vybrané příznaky a klasifikátory.

KLÍČOVÁ SLOVA

Segmentace buněk, zpracování obrazu, klasifikace pixelů.

ABSTRACT

This Bachelor thesis deals with cell segmentation by pixel classification of various microscopic modalities. There is a summary of possible features and also some of the classifier suitable for this kind of segmentation are mentioned here. In the practical part of the thesis, there are results for chosen features and classifier.

KEYWORDS

Cell segmentation, image preprocessing, pixel classification.

VÝVODA, Jan. *Segmentace buněk pomocí klasifikace pixelů ve snímcích z různých mikroskopických modalit*. Brno, 2020, 68 s. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Tomáš Vičar

PROHLÁŠENÍ

Prohlašuji, že svou bakalářskou práci na téma „Segmentace buněk pomocí klasifikace pixelů ve snímcích z různých mikroskopických modalit“ jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autora

PODĚKOVÁNÍ

Rád bych poděkoval svému vedoucímu bakalářské práce panu Ing. Tomáši Vičarovi, za odborné vedení, konzultace, trpělivost, návrhy a další cenné rady.

Obsah

Úvod	10
1 Předzpracování obrazu	11
1.1 Operace s kontrastem	11
1.1.1 Ekvalizace histogramu	11
1.1.2 Transformace jasové stupnice	11
1.2 Lokální operátory	14
1.2.1 Lineární lokální operátory	14
1.2.2 Detekce hran	14
1.3 Texturní analýza	15
1.3.1 Matice společného výskytu	16
1.3.2 Matice délek běhů	16
1.3.3 Hodnocení autokorelace	17
1.3.4 Funkce ve frekvenční oblasti	17
1.3.5 Lokální hessián obrazu	18
1.3.6 Gaborovy filtry	20
2 Výběr podmnožiny příznaků	21
2.1 Metoda minimální redundance a maximální relevance	21
2.2 Dopředný a zpětný výběr podmnožiny příznaků	22
2.3 Analýza hlavních komponent	23
3 Segmentace	25
3.1 Prahování	25
3.2 Dělení a slučování oblastí	26
3.3 Narůstání oblastí	26
3.4 Metoda rozvodí	27
3.5 Houghova transformace	27
3.6 Aktivní kontury	28
3.7 Segmentace klasifikací pixelů	28
4 Klasifikátory	30
4.1 K-nejbližších sousedů	30
4.2 Náhodný les	31
4.3 Metoda podpurných vektorů	32
4.4 Naive Bayes	34
4.5 Neuronové sítě	36

5	Dataset	38
6	Vyhodnocení výsledků	40
6.1	Implementace vybraných klasifikátorů	40
6.2	Vyhodnocení použití samostatných příznaků	41
6.3	Výběr a vyhodnocení podmnožin příznaků	45
6.3.1	Podmnožiny vybrané dopřednou metodou	47
6.3.2	Podmnožiny vybrané metodou mRMR	49
7	Diskuze výsledků	53
7.1	Výběr příznaků	53
7.2	Výběr klasifikátorů	54
7.3	Výsledná segmentace	54
	Závěr	58
	Literatura	59
	Seznam symbolů, veličin a zkratk	63
A	Další vybrané výsledky	64

Seznam obrázků

1.1	Ekvalizace histogramu	12
1.2	Histogramy lineární transformace	13
1.3	Histogramy gama transformace	13
1.4	Lokální binární vzor	18
1.5	Funkce ve frekvenční oblasti	19
2.1	Princip metody PCA	23
3.1	Sémantická a případová segmentace	25
3.2	Dělení a slučování oblastí	26
3.3	Metoda rozvodí	27
4.1	Princip klasifikátoru kNN	31
4.2	Princip klasifikátoru SVM	33
4.3	Princip neuronové sítě	36
5.1	Snímky DIC, HMC, PC a QPI	39
6.1	Porovnání snímků s různým množstvím pixelů	41
6.2	Původní a referenční snímek	42
6.3	Snímky příznaků vytvořených ostrícemi maskami 6.4	43
6.4	Snímky segmentovaného obrazu pomocí příznaků z texturní analýzy	44
6.5	PCA analýza	46
6.6	Graf nejlepších výsledků pro dopřednou metodu	49
6.7	Graf nejlepších výsledků pro metodu mRMR	52
7.1	Snímek segmentace modality QPI	55
7.2	Snímek segmentace modality HMC	55
7.3	Snímek segmentace modality DIC	56
7.4	Snímek segmentace modality PC	56
7.5	Porovnání modalit HMC, DIC, PC	57

Seznam tabulek

6.1	Tabulka porovnání výsledků klasifikátorů	41
6.2	Tabulka porovnání výsledků jednotlivých příznaků ostřících masek . .	42
6.3	Tabulka porovnání výsledků jednotlivých příznaků texturní analýzy .	43
6.4	Tabulka vyhodnocení detekce hran	43
6.5	Seznam použitých příznaků pro klasifikaci	45
6.6	Tabulka výsledků dopředné metody DIC snímku	47
6.7	Tabulka výsledků dopředné metody HMC snímku	48
6.8	Tabulka výsledků dopředné metody QPI snímku	48
6.9	Tabulka výsledků dopředné metody PC snímku	49
6.10	Tabulka výsledků metody mRMR DIC snímku	50
6.11	Tabulka výsledků metody mRMR HMC snímků	51
6.12	Tabulka výsledků metody mRMR QPI snímků	51
6.13	Tabulka výsledků metody mRMR PC snímků	51
A.1	Kombinace výsledků dopředné a mRMR metody modality DIC	64
A.2	Kombinace výsledků dopředné a mRMR metody modality HMC . . .	65
A.3	Kombinace výsledků dopředné a mRMR metody modality QPI	65
A.4	Kombinace výsledků dopředné a mRMR metody modality PC	66
A.5	Další nastavení klasifikátorů pro DIC modalitu.	66
A.6	Další nastavení klasifikátorů pro HMC modalitu.	67
A.7	Další nastavení klasifikátorů pro QPI modalitu.	67
A.8	Další nastavení klasifikátorů pro PC modalitu.	68

Úvod

Segmentace živých buněk je extrémně důležitý proces pro současný výzkum buněk a řadí se do oblasti zpracování biomedicínských obrazů. Studie prokázala, že dnešní metody pro segmentaci buněk nejsou stále uspokojivé a je možné je dále zlepšit. Je nutný výzkum technik vhodných pro heterogenní buněčné populace a pro zobrazovací techniky, které neumožňují specifické označení sledovaných objektů. Segmentace je důležitá část zpracování obrazu pro další možné analýzy objektů, které se na snímku objevují. V této práci je popsána segmentace snímků buněk na základě klasifikace pixelů. Principem je předpracování snímků, kterému se věnuje první kapitola této práce, čímž dojde k vytvoření příznaků pro klasifikátor, který je vždy naučen na množině trénovacích dat, tedy trénovacích snímků. Samozřejmě se k segmentaci obrazů nevyužívají všechny možné typy předzpracování, ale je potřeba se vždy zaměřit na morfologii daného snímku. Je tedy potřeba vybrat určitou podmnožinu příznaků, čemuž se věnuje druhá kapitola. Samotnému popisu klasifikátorů se věnuje čtvrtá kapitola, kde jsou popsány jedny z nejpoužívanějších metod a to k-nejbližších sousedů, náhodný les, SVM, naive Bayes a neuronové sítě. V práci jsou popsány také jiné metody segmentace jako je prahování, narůstání oblastí, metoda rozvodů a jiné. V posledních kapitolách se budeme věnovat vyhodnocení některých metod pro výběr vhodných příznaků a některých klasifikátorů zmíněných výše, pro různé mikroskopické modality.

1 Předzpracování obrazu

1.1 Operace s kontrastem

Transformace kontrastu je skupina metod, které umožňují zvýrazňování obrazů tak, aby měl pozorovatel lepší subjektivní vizuální vjem (pozorovateli je tedy obraz příjemnější a lépe se mu na něj dívá), může dojít např. ke korigování nerovnoměrné expozice. Jedná se tzv. bodové operátory, kdy k vytvoření výsledného pixelu se využívá pouze pixel vstupní, nikoli i jeho okolí, jako je tomu u operátorů lokálních. Při těchto úpravách je potřeba brát na vědomí, že ačkoli se vizuální vjem z výsledného obrazu zlepší, může dojít ke ztrátě části informace. Výstupem tohoto zvýraznění je opět obraz. [2]

1.1.1 Ekvalizace histogramu

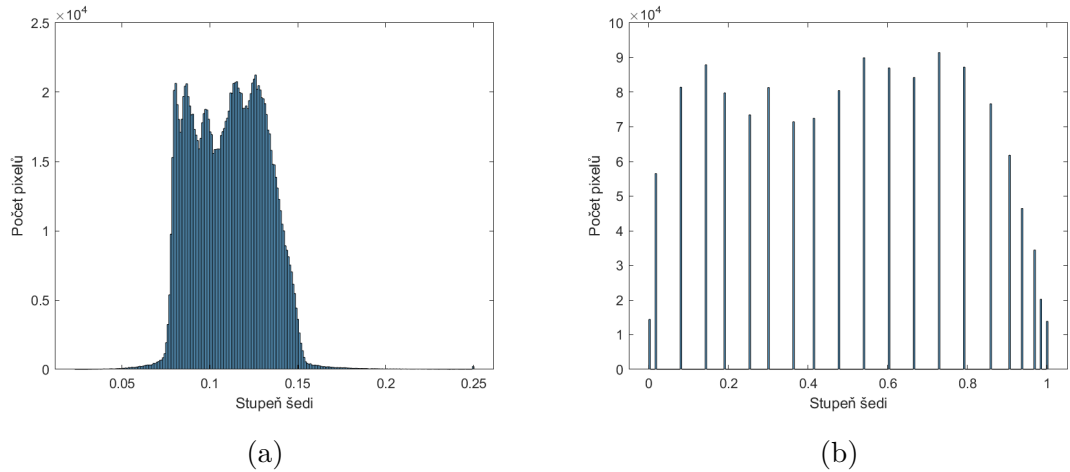
Ekvalizace histogramu je metoda upravující obraz za použití transformace jeho histogramu. Cílem je vytvořit výsledný obraz, který má v ideálním případě rovnoměrně zastoupeny všechny jasové hodnoty. Dochází tedy ke zlepšení kontrastu na základě jeho neklesající lineární transformace. [4] Máme původní obraz $f(x, y)$, o rozměrech $m \times n$, jehož histogram označíme h^f . Výsledný obraz $g(x, y)$ a jeho histogram h^g s počtem stupňů šedi q . Pokud bychom se bavili o ideálním případě, tak v ekvalizovaném histogramu (h^g), bude každá jasová úroveň (složka) zastoupena $m \times n/q$ pixely. Jelikož jde o transformaci neklesající, tak je každá složka výsledného histogramu počítána jako suma sousedních hodnot histogramu původního, podle rovnice

$$h_l^g = \sum_{k=k_l}^{k_l + \Delta k_l} h_k^f, \quad (1.1)$$

kde h_l^g je výsledný histogram, h_k^f je histogram původní a hodnota k určuje počet úrovní původního histogramu. Pro výpočet úrovně výsledného histogramu platí podmínka, že k sumaci dochází do té doby, dokud hodnota úrovně výsledného histogramu není větší, než hodnota $m \times n/q$ a zároveň po přičtení další složky původního histogramu, by došlo k překročení této hodnoty. Pokud dojde k překročení povolené výšky sloupečku, tak se vynechávají následující jasové úrovně, jako je vidět na obrázku 1.1. [1]

1.1.2 Transformace jasové stupnice

Transformace jasové stupnice je úprava obrazu, která platí stejně na všechny pixely obsažené ve vstupním obraze. Je obecně dána rovnicí



Obr. 1.1: Obrázek (a) zobrazuje histogram původního snímku a obrázek (b) pak histogram ekvalizovaný.

$$g_{i,k} = T(f_{i,k}) \quad (1.2)$$

Tuto rovnici lze chápat, jako transformaci stupňů šedi $f \in \langle f_0, f_k \rangle$ původního obrazu, na stupně šedi výsledného obrazu $g \in \langle g_0, g_k \rangle$. [3]

Mezi tyto metody řadíme po částech lineární transformaci jasové stupnice, která je navržena tak, aby došlo k využití celé škály jasové stupnice, nejde však o rovnoměrné zastoupení jednotlivých stupňů šedi, jako u ekvalizace histogramu, ale pouze o roztažení původního histogramu, jak je vidět z obrázku 1.2.[2] Tato transformace je matematicky vyjádřena podle rovnice


$$g_{i,k} = \frac{f_{i,k} - \min(f)}{\max(f) - \min(f)}, \quad (1.3)$$

kde f je původní a g výsledný obraz. Vytvoření negativu je další metodou transformace jasu. Jejím principem je převrácení původního histogramu, tedy záměna tmavých stupňů šedi za světlé a naopak, světlých za tmavé. [3]

Dále můžeme zmínit transformace nelineární na rozdíl od již zmíněných. Řadíme sem transformaci exponenciální, která je definována vztahem

$$g_{i,k} = Z^{f_{i,k}}, \quad (1.4)$$

kde Z je základ této funkce a pokud je zvolen z intervalu $\langle 0,1 \rangle$, tak vzniká klesající konvexní funkce. S limitním přibližováním k základu jedna se funkce postupně linearizuje a blíží se funkci negativu. Pokud však zvolíme koeficient větší než jedna, pak transformační funkce bude mít rostoucí tendenci. Výstupní obraz je však nutné normalizovat, jelikož by obsahoval hodnoty mimo interval $\langle 0,1 \rangle$. [2]




Obr. 1.2: Na snímku (a) je histogram původního obrazu a na snímku (b) je pak histogram obrazu upraveného lineární transformací, který je roztažen přes celou jasovou škálu.

Gama korekce je další nelineární metoda používaná k transformaci jasové stupnice obrazu. Ta se na základě zvoleného exponentu γ chová jinak ke tmavým a světlým pixelům. Pokud zvolíme exponent $\gamma > 1$, tak dochází ke zvýšení množství velmi tmavých pixelů (křivka transformační funkce má tvar konvexní). Když naopak zvolíme $\gamma < 1$, pak dojde ke zvýšení počtu světlých pixelů (křivka má tvar konkávní). Histogramy jsou vyobrazeny na obrázku 1.3, kde je možné vidět rozdíl vlivu γ koeficientu na světlé a tmavé pixely. Obecná rovnice pro gama korekci je potom

$$g_{i,k} = f_{i,k}^{\gamma}, \quad (1.5)$$

kde f je původní obraz a g je obraz výsledný.[1]



Obr. 1.3: Na obrázku (a) je histogram původního obrazu, na obrázku (b) pak histogram po gamma korekci za použití $\gamma < 1$ a (c) představuje histogram za použití $\gamma > 1$.

1.2 Lokální operátory

V této kapitole se budeme bavit o lokálních operátorech (filtrech), což jsou metody, které využívají vždy jen malého okolí konkrétního pixelu k jeho úpravě na pixel výstupní. V praxi tedy dochází k postupnému procházení obrazu za pomoci malého obdélníku, v jehož středu se nachází právě konkrétní pixel, který je upravován.[3] Podle [6] můžeme lokální operátory dělit do několika skupin. Podle použití je rozdělujeme do operátorů vyhlazovacích a operátorů detekujících hrany. Dále podle vlastností jejich rovnic na operátory lineární a nelineární.

1.2.1 Lineární lokální operátory

Lineární lokální operátory se používají nejčastěji pro filtraci Gaussovského šumu, který má normální rozložení, což znamená, že míra šumu je na všech pixelech stejná. Do těchto operátorů patří hned několik metod.

Jako první bych zmínil prosté průměrování jehož principem je konvoluční maska v podobě matice, která má všechny prvky stejné. Následně můžeme ovlivňovat stupeň odstranění šumu změnou centrálního prvku, nebo změnou velikosti samotné masky, kdy se zvětšující se maskou dochází k výpočtu výsledného pixelu z většího počtu okolních pixelů, a tak je potlačení šumu větší. Konvoluční operátory pracují také na principu masky s centrálním prvkem, procházející obraz, kde ale výsledný pixel je vypočítán na základě rovnice převzaté z [6]:

$$g(x, y) = \sum_{m=-k/2}^{k/2} \sum_{n=-k/2}^{k/2} l(x-m, y-n) \cdot f(m, n) = (l * f)(x, y) \quad (1.6)$$

Kde l je konvoluční maska, proměnná f je vstupní, g výstupní obraz a (m, n) jsou pozice obdélníkového okolí o velikosti $k \times k$.

Je také nutno masku normalizovat, aby nedocházelo k přidání energie do obrazu. Normalizace se provede vydělením masky součtem hodnot všech jejích prvků. [2] Velkou nevýhodou prostého průměrování je poměrně velké rozmazání výsledného obrazu, a to hlavně v oblastech s prudkou změnou jasu, tedy na hranách. Existují také filtry, které filtrují vysoké frekvence, pomocí který je možné zvýraznit právě zmíněné hrany objektů. Zvýrazňují se tak především objekty, které nejsou větší než polovina velikosti filtrovací masky. Naopak filtry filtrující nízké frekvence pak vyhlazuje obraz a snaží se tedy snížit rozdíl centrálního pixelu od jeho okolí.[4]

1.2.2 Detekce hran

O hranové detekci lze říci, že je to jakási transformace šedotónového obrazu na obraz binární, kdy bílé pixely jsou hranice objektů a ty černé pak okolí. K detekci hran se

používá hned několika detektorů. Jako první si řekneme něco o lokálních operátorech aproximujících první derivaci. U těchto operátorů dochází k vytvoření lokálního extrému v místě, kde se nachází hrana. Využívá se tzv. kompasových detektorů, což jsou konvoluční masky, které detekují hrany vždy v jednom směru (zpravidla horizontální a vertikální směr). Řadíme sem masky Robertsovy, Sobelovy, Kirschovy a Prewittové [2]. Výsledný obraz $g_{i,k}$ je potom vypočítán podle rovnice

$$g_{i,k} = \sqrt{(\Delta_x f_{i,k})^2 + (\Delta_y f_{i,k})^2}, \quad (1.7)$$

kde $\Delta_x f_{i,k}$ představuje obraz aproximující parciální derivace ve směru osy x a $\Delta_y f_{i,k}$ pak osy y . [1]

Dále se využívá detektorů, které aproximují druhou derivaci a následně se detekují průchody nulou pomocí tzv. Zero-crossing operátorů. Principem je upravení obrazu pomocí operátoru Laplacián, nebo Laplacián Gaussiánu (LoG) [2]. Po upravení obrazu těmito operátory musí dojít k detekci průchodu nulou v obraze, jelikož Laplacián je nulový tam, kde je velikost gradientu maximální [5]. Operátor LoG (Laplacian of Gaussian) se používá kvůli tomu, že samotný Laplacián je velmi náchylný na šum v obraze, proto se využívá konvoluce obrazu s maskou Gaussiánu, která obraz vyhladí [1].

Obraz gradientů musí být nadále upraven, aby vzniklé hrany měly tloušťku 1 pixel, a aby byly co nejméně přerušované. Abychom toto zajistili, je potřeba vypočítat směr gradientu, následně se určí směr hrany v každém bodu a dále se normalizuje do určitého směru. Může to být buď vertikální, horizontální, nebo jedna z diagonál. Pak se postupem po hraně v jejím směru potlačí pixely, které nejsou hranové. Potom je možné provést prahování s hysterezí, jehož principem je volba dvou prahů. P_H , tedy horní práh a dolní práh P_D jsou nastaveny tak, aby pixely, které patří do skupiny nad hodnotou horního prahu byly zařazeny jako pixely hrany a pixely pod hodnotou dolního prahu pak zařazeny jako ty nehranové. Následně se rozhoduje o pixelech v rozmezí těchto dvou prahů. Hledá se, jestli daný pixel sousedí s hranovým pixelem, či nikoli. Takto probíhá několik iterací dokud nejsou dvě po sobě jdoucí iterace bez změny. Tento postup se uplatňuje u Cannyho detektoru hran. [24]

1.3 Texturní analýza

Textury se v obrazech objevují dost často a jsou velmi dobře rozpoznatelné lidským okem. Slouží nám k rozpoznání hranic a celkového charakteru obrazu, jako jsou typy povrchu, struktur, tvarů a objektů. Textura se dá obecně definovat jako oblast obrazu, ve které mají změny jasu charakteristické vlastnosti, jeví se jako uniformní. Textury bývají tvořeny z tzv. primitiv (nebo texelů), což jsou malé objekty, které

jsou uspořádány buď pravidelně, nebo nepravidelně a dohromady tvoří výslednou texturu. Texturey můžeme dělit na základě druhů primitiv. Pakliže jsou texely malé, jedná se o jemné texturey. Pro velká primitiva jsou to pak texturey hrubé. Podle pravidelnosti uspořádání na texturey silné, s pravidelným uspořádáním a slabé s nepravidelným uspořádáním. Texturní analýza může být využita pro klasifikaci, kdy je potřeba vyhodnocovat co největší oblast homogenní texture, aby došlo k větší přesnosti klasifikace, a také pro segmentaci, kdy je naopak potřeba vyhodnocovat co nejmenší oblast, aby bylo prostorové rozlišení co nejlepší [2].

1.3.1 Matice společného výskytu

Tato metoda vyhodnocuje míru opakovaných kombinací intenzity pixelů f , f' pro páry pixelů, které jsou umístěné ve vzájemné poloze se vzdáleností Δr a směrem ϕ . Přesná definice této metody může být založena na konceptu společných histogramů. Mějme obraz s q hodnotami šedi, okolí pixelu (x, y) a okolí stejného tvaru a velikosti, které patří k pixelu $(x + \Delta x, y + \Delta y)$. Je to matice společného výskytu s parametrem posunu $(\Delta x, \Delta y)$. Tyto oblasti se dají brát za stejně velké a je možné pro ně vytvořit společný histogram tvoření $q \times q$ velkou maticí. Matice nese informaci o kombinacích úrovně šedi na daných pixelech bez ohledu na jejich polohu.

Textura je následně popsána několika takovými histogramy. Dané parametry posunu jsou obvykle vyjádřeny pomocí již zmíněné vzdálenosti Δr a směru ϕ . Často se pro ϕ berou násobky 45° (0° , 45° , 90° a 135°). Pak Δr je celé číslo vzorkovací vzdálenosti pro vertikální a horizontální směr, pro šikmé směry pak $\sqrt{2}$ krát větší. Často se používá pouze 8 sousedních pixelů. Z výsledných histogramů se dá vyvodit několik charakteristik a to například: Entropie, energie, modus, kontrast, korelace a lokální homogenita. [1].

1.3.2 Matice délek běhů

Průběhem je myšlena nepřerušovaná sekvence pixelů s identickým stupněm šedi a určitým směrem. Principem je dvourozměrný histogram (matice), kde jeden rozměr tvoří stupeň šedi a druhý pak délka průběhu. Kdy pro každý směr (0° , 45° , 90° a 135°) je vytvořena nová matice. Představme si, že původní obrázek je následovný:

$$A = \begin{bmatrix} 0 & 0 & 2 & 2 \\ 1 & 1 & 0 & 0 \\ 3 & 2 & 3 & 3 \\ 3 & 2 & 2 & 2 \end{bmatrix}, \quad (1.8)$$

kde jednotlivé pixely nabývají hodnot šedi od 0 do 3. Pak matice délek běhů pro 0° bude vypadat takto:

$$Q_{RL}(0^\circ) = \begin{bmatrix} 0 & 2 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 \\ 2 & 1 & 0 & 0 \end{bmatrix}, \quad (1.9)$$

zde sloupce představují délku sekvence pixelů (jeden pixel, dvojice, trojice a čtveřice pixelů) se stejnou hodnotou a řádky pak představují hodnotu šedi (první řádek pro hodnotu 0, druhý pro 1 atd.). Pro 45° by pak matice vypadala následovně [10]:

$$Q_{RL}(45^\circ) = \begin{bmatrix} 4 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0 \\ 6 & 0 & 0 & 0 \\ 4 & 0 & 0 & 0 \end{bmatrix}. \quad (1.10)$$


Na základě těchto matic pak mohou být vypočítány charakteristiky jako je Short-run emphasis(SRE), Long-run emphasis(LRE), Gray-level nonuniformity(GLNU), Run length nonuniformity (RLN), Run percentage(RP) [12].

1.3.3 Hodnocení autokorelace

Jelikož je autokorelace jako funkce poměrně velká, tak se používají deskriptory odvozené od této funkce. Jedním z nich je Lokální binární vzor, anglicky Local binary pattern (LBP). Jako první je potřeba převést obraz na šedotónový. Následně si musíme určit velikost okolí každého pixelu, které označíme r . Potom je LBP hodnota vypočítána pro daný centrální pixel a uložena do 2D matice o stejné velikosti jako vstupní obraz. Kromě velikosti okolí je možné volit také koeficient p , který určuje počet pixelů, se kterými budeme v okolí počítat. Samotný výpočet LBP je pak následovný. Vybereme centrální pixel, který má určitou hodnotu. Tato hodnota funguje jako práh pro hodnocení okolních pixelů. Pokud je centrální pixel větší než okolní, pak okolní pixel dostane hodnotu 1, v opačném případě bude roven 0. Následně počítáme hodnotu LBP pro centrální pixel. Počítat začínáme kterýmkoli okolním pixelem a pokračujeme buď po, nebo proti směru hodinových ručiček. Zvolený směr však musí být pro výpočty v celém obraze a pro všechny obrazy stejný. Následně binární hodnoty převedeme do decimální soustavy, čímž získáme hodnotu centrálního pixelu.[30] Proces je zobrazen na obrázku 1.4.

1.3.4 Funkce ve frekvenční oblasti

Použití lokální transformace na samotný pixel, nebo jeho velmi malé okolí znemožní dosažení vysokého spektrálního rozlišení. Proto se vždy vybírají centrální pixely se




Obr. 1.4: Schéma principu výpočtu centrálního pixelu pro metodu Lokálního binárního vzoru.

svým okolím. Okolí daných centrálních pixelů se překrývají s okolím sousedního centrálního pixelu zpravidla o jednu až dvě třetiny velikosti v každé dimenzi. Při použití klasické diskrétní Fourierovy transformace dochází k tomu, že jednotlivé spektrální koeficienty mají příliš vysokou hodnotu variance a tedy jsou nespolehlivé. Proto se využívá určitých seskupení, které jsou zobrazeny na obrázku 1.5, je to například energie vybraného frekvenčního pásma. Ty jsou poskládány do prstenců a poskytují tak informace o převládajících prostorových frekvencích jako na obrázku 1.5b. Další možností je seskupení klínové, které představuje celkovou energii pro daný směr, pomocí čehož lze vyhodnotit prostorovou orientaci změn lokálních intenzit obrazu, což je možné pozorovat na obrázku 1.5a. Pokud zkombinujeme obě metody, tak vytvoříme aproximaci spektra, která podává informaci o směru a absolutním rozdělení frekvencí. Toto lze hezky vidět na obrázku 1.5c. [11]

1.3.5 Lokální hessián obrazu

Hessova matice je čtvercová matice, která je tvořena parciálními derivacemi druhého řádu skalární funkce[13].



Obr. 1.5: Na obrázku (a), je možné vidět klínové seskupení, kde je zobrazena energie daného frekvenčního pásma. Na obrázku (b) je pak vybrána energie frekvenčního pásma prstencového seskupení. Na posledním snímku je kombinace obou seskupení. [1]

$$H = \begin{bmatrix} I_{xx} & I_{xy} \\ I_{xy} & I_{yy} \end{bmatrix}, \quad (1.11)$$

s tím, že I_{xx} , atd. jsou parciální derivace druhého řádu. Tato parciální derivace představuje hledání hrubých textur a rohů ve směrech os x , y a xy , tedy hledání prudkých změn jasu. Jako detektor maxim v obraze můžeme použít determinant (Hessián) Hessovy matice, který se počítá podle následující rovnice [14]:

$$\det(H) = I_{xx}I_{yy} - I_{xy}^2. \quad (1.12)$$

Kromě hessiánu vypočítaného pomocí parciálních derivací můžeme použít také vlastní čísla Hessovy matice, které pojmenujeme λ_1 a λ_2 . Vlastní čísla zde představují velikost zakřivení textur v obraze, kde λ_1 je pro nejvyšší zakřivení a λ_2 pro nejnižší. Mohou nastat čtyři situace [13].

- $|\lambda_1| = |\lambda_2|$ znamená, že je zakřivení v obou směrech stejné.
- $|\lambda_1|, |\lambda_2| \approx 0$ platí pro rovinu, kde nedochází k žádnému zakřivení.
- $|\lambda_1| > 0, |\lambda_2| \approx 0$, kdy v jednom směru se zakřivení mění a ve druhém nikoli.
- $|\lambda_1| > 0, |\lambda_2| > 0$, v jednom směru je zakřivení větší, než ve směru druhém.

Pomocí vlastních čísel také můžeme vypočítat determinant Hessovy matice, a to podle rovnice:

$$\det(H) = \lambda_1 \cdot \lambda_2, \quad (1.13)$$

pomocí kterého opět najdeme maxima v obraze [20].

1.3.6 Gaborovy filtry

Tyto lineární filtry se používají především pro texturní analýzu, a tedy analyzují, zda se v obraze vyskytují specifické frekvence v určitých směrech v oblasti zájmu. V 2D prostoru jsou Gaborovy filtry složeny z gaussovske funkce modulované sinusovou vlnou. Tyto filtry mají část reálnou a imaginární, které představují ortogonální směry a mohou být zapsány buď v podobě komplexní, nebo každá zvlášť:

$$g(x, y; \lambda, \theta, \gamma, \sigma, \psi) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi\frac{x'}{\lambda} + \psi\right)\right), \quad (1.14)$$

zde $x' = x\cos\theta + y\sin\theta$, $y' = -x\sin\theta + y\cos\theta$. Dále θ představuje orientaci, λ je vlnová délka sinusoidy, ψ je fázový rozdíl, γ je prostorové hledisko a σ je směrodatná odchylka obálky Gaussovy funkce [21].

V praxi se využívá banka Gaborových filtrů s různými rotacemi. Filtry jsou následně spojeny se signálem, čímž se vytvoření tzv. Gaborův prostor [22].

2 Výběr podmnožiny příznaků

Pro segmentaci však není moc důležité statisticky hodnotit samostatné příznaky, proto je potřeba využít některých algoritmů, které jsou schopny vybrat nejlepší kombinaci příznaků, tedy podmnožinu, která je pro segmentaci daného obrazu nejprínosnější. Existuje několik druhů takových algoritmů. Jedním z nich jsou tzv. filtrační metody, které jsou založené na vybírání příznaků bez závislosti na klasifikátoru a tedy hodnotí vztah mezi samotnými příznaky a vztah mezi příznakem a referencí.[26] Mezi tyto metody patří metoda minimální redundance a maximální relevance, neboli mRMR. Dále jsou to wrapper metody, které jsou na rozdíl od těchto filtračních, na klasifikátoru závislé. Statisticky je tedy vyhodnocena výsledná segmentace daného příznaku, popřípadě podmnožiny příznaků a na základě těchto výsledků je pak vybrána daná podmnožina. Jako poslední jsou vestavěné (embedded) metody. Tyto metody jsou tedy schopny vybírat podmnožinu příznaků v průběhu učení klasifikátoru.[31]

2.1 Metoda minimální redundance a maximální relevance

Jak již bylo zmíněno, tento algoritmus patří do skupiny filtračních metod. Zjišťuje zde vzájemné korelace mezi jednotlivými příznaky (Redundance) a zároveň důležitost (Relevance) daného příznaku pro segmentaci obrazu, tedy porovnává se vztah příznaku s předlohou. K výpočtu jsou použity dva vzorce

$$Relevance = \frac{1}{|S|} \sum_{x_i \in S} I(x_i; y) \quad (2.1)$$

$$Redundance = \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j), \quad (2.2)$$

kde $|S|$ je počet příznaků v podmnožině, I je vzájemná informace, která je počítána pomocí entropie obrazu, x_i a x_j jsou pixely, mezi kterými se zjišťuje vzájemná korelace a y je pixel předlohy.

K výpočtu entropie byl použit vzorec

$$E = - \sum_i P_i \log_2 P_i, \quad (2.3)$$

kde P je pravděpodobnost výskytu daného stupně šedi.

Následně je použito vzorce, který představuje výpočet vzájemné informace pomocí již spočítané entropie

$$I(x, y) = E(x) + E(y) - E(x, y), \quad (2.4)$$

kde $E(x)$ a $E(y)$ jsou entropie jednotlivých příznaků a $E(x, y)$ je sdružená entropie, což je jakási míra nejistoty mezi příznakem x a předlohou y . Její výpočet je velmi podobný již zmíněnému výpočtu klasické entropie, avšak je zde použita pravděpodobnost společného výskytu příznaku x a y .

Po vypočítání relevance a redundance podle vzorců 2.1 a 2.2 se bere v potaz jejich rozdíl $Rel - Red$, kdy hledáme podmnožinu (subset) příznaků, které dosahují maximální hodnoty tohoto rozdílu. Princip hledání této podmnožiny je velmi podobný metodě dopředné, kdy tedy zvolíme počáteční příznak s nejlepším rozdílem $Rel - Red$ a následně jsou k němu postupně přidávány další příznaky, jejichž společný výsledek $Rel - Red$ je zase maximální [25].

2.2 Dopředný a zpětný výběr podmnožiny příznaků

Tyto dvě metody se řadí do wrapper metod. Dochází tedy k výběru určité podmnožiny příznaků pomocí statistického hodnocení výsledků klasifikace pixelů [26]. U obou metod je počítáno DSC, neboli F1-skóre podle vzorce

$$DSC = \frac{2 \sum TP}{2 \sum TP + \sum FP + \sum FN} \quad (2.5)$$

Dopředná a zpětná metoda jsou zjednodušeně opakem. Principem dopředné metody je výběr nejlepšího příznaku na základě F1-skóre. Následně je k němu přiřazen další příznak, jejichž společné F1-skóre dosahuje maximální hodnoty. Takto jsou dále přidávány další příznaky, podle toho, kolik jich je požadováno do podmnožiny. U zpětné metody je nejprve nutné spočítat celkové F1-skóre pro všechny dostupné příznaky, ze kterých vybíráme subset. Následně jsou odebírány ty příznaky, při jejichž odstranění došlo k minimálnímu poklesu F1-skóre. K tomuto opět dochází dokud není dosaženo požadovaného počtu příznaků do výsledné podmnožiny [27]. Hlavní výhoda těchto metod je taková, že proces nalezení vhodné podmnožiny je mnohem méně výpočetně náročný, než pokud bychom zkoušeli všechny možné kombinace podmnožin. Pokud bychom vzali v potaz dopřednou metodu, pomocí které hledáme podmnožinu pěti příznaků z celkových deseti. Pak výpočet zabere čtyřicet cyklů, během kterých se tedy $40 \times$ vyhodnocuje klasifikace. Pakliže bychom hledali takovou podmnožinu pěti příznaků náhodně, tak existuje 30240 možných podmnožin, které by musely být testovány, tedy tolikrát by musela proběhnout klasifikace. Nevýhodou však je, že tyto filtrační metody neberou v potaz vzájemné ovlivňování mezi příznaky.

2.3 Analýza hlavních komponent

Analýza hlavních komponent, neboli PCA, je metoda úpravy dat, jejíž úkol je zmenšit rozměrnost velkého setu dat na set menší, který ale podá přibližně stejně velkou informaci, jako obsahoval původní velký set. Provádí se to hlavně z toho důvodu, protože s menší sadou dat se mnohem lépe pracuje, dá se lépe interpretovat a není tak náročná na zpracování pro některé algoritmy strojového učení [28]. PCA se, zjednodušeně, provádí tak, že první komponenta je osa, která reprezentuje největší rozptyl dat. Druhá komponenta je pak osa kolmá na tu první. Pak se tedy data zobrazí v nové soustavě, jako je vidět na obrázku 2.1. Komponent, tedy os, může být několik.


Prvním krokem PCA je standardizace dat, kdy se snažíme dostat data do stejného rozsahu hodnot, aby nebyla některá dominantní oproti ostatním. Z těchto standardizovaných dat se následně vytváří matice kovariancí, což je čtvercová symetrická matice, která popisuje vzájemnou korelaci mezi jednotlivými proměnnými a získáme ji pomocí výpočtu

$$K = X^T X, \quad (2.6)$$

kde K je matice kovariancí a X je původní matice dat. Dalším krokem je výpočet vlastních čísel a vektorů pomocí matice kovariancí, pro která platí

$$KV = \lambda V, \quad (2.7)$$

kde K je matice kovariancí, V je matice vlastních vektorů a λ je matice vlastních čísel.




Obr. 2.1: Snímek nalevo zobrazuje data reprezentována příznaky X_1 a X_2 . Následně je těmito daty proložena první hlavní komponenta (PC1) tak, aby reprezentovala největší rozptyl dat. Dále je vytvořena druhá komponenta (PC2) kolmá na PC1.

Pomocí nich pak můžeme určit vlastní komponenty. Počet vlastních vektorů a jejich vlastních čísel je roven počtu našich proměnných. Můžeme říci, že vlastní vektory určují směr největší odchylky, tedy největší informace v datech, což lze nazývat hlavním komponentem. Vlastní čísla jsou jakési koeficienty přiřazené k vlastním vektorům, které určují velikost odchylky dané hlavní komponenty. Podle velikosti vlastních čísel tak můžeme řadit vlastní vektory podle jejich důležitosti, tedy podle toho, jak velké množství informace nesou. Zpravidla je potřeba zanechat ty vektory, které nesou alespoň 90% informace. Takto dochází k redukci dat, kdy se zbavíme několika proměnných, ale stále je k dispozici alespoň 90 % původní informace. Dále vytvoříme tzv. Feature vector, což je matice, které ve sloupcích obsahuje jednotlivé vlastní vektory, které jsme ponechali. Následně už jen stačí převést data na osy hlavních komponent, což se provede násobením Feature vektoru a matice původních příznaků. [29].

3 Segmentace

Segmentace patří do základních metod analýzy obrazu. Principem je rozdělení obrazu na jednotlivé oblasti zájmu, které se nepřekrývají a mají souvislost s hledaným obsahem. Jedná se tedy často o hranice objektů, nebo o objekty jako takové. Výsledný obraz, je stejně velký, jako obraz vstupní, avšak pohledově se obraz liší, jelikož je rozdělen na jednotlivé segmenty. Segmentaci lze dělit na dvě skupiny. Sémantickou a případovou segmentaci. V případě sémantické segmentace jde o rozdělení objektů do skupin předem známých, tedy jako například u klasifikace pixelů kdy je známo, že určité pixely jsou pixely buňky a jiné jsou součástí pozadí. U případové segmentace se zachází více do hloubky. Třídy nejsou předem definovány a tedy každá buňka je segmentována jako jiný případ.[32] Výsledná segmentace obou metod je naznačena na obrázku 3.1.



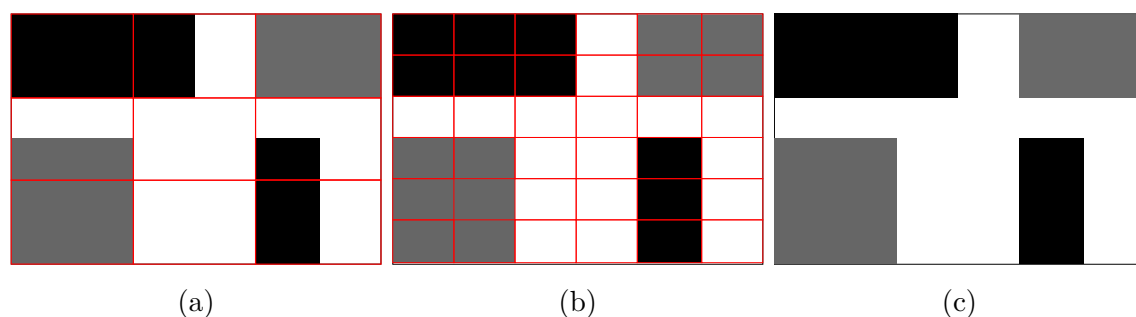
Obr. 3.1: Na snímku (a) je zobrazena segmentace buněk sémantickou segmentací. Na snímku (b) je segmentace případová, kde každá buňka je klasifikována zvlášť.

3.1 Prahování

Prahování je jednou ze základních a nejstarších metod segmentace. U této metody se volí určitý práh, podle kterého je následně obraz rozdělen do oblastí, které obsahují hodnoty buď nadprahové, a nebo podprahové. Může tedy dojít k rozdělení např. na objekty a pozadí. Je také možné zvolit více prahů a tedy obraz bude rozdělen na více oblastí [1].

3.2 Dělení a slučování oblastí

Tato metoda je založená na dělení obrazu na základě homogenity oblastí. Samotné dělení si můžeme představit pomocí pyramidové reprezentace. Máme tedy nějakou oblast v obraze, o které je rozhodnuto na základě počátečního kritéria, že není homogenní. Následně dojde k rozdělení této oblasti do čtyř dceřinných oblastí. A takto pokračujeme dokud nedojdeme ke stavu homogenity v dané oblasti. Následně dochází ke spojení sousedních dceřinných oblastí, které vznikly z různých oblastí viz Obr.3.2a, 3.2b a 3.2c [1].



Obr. 3.2: Na obrázku (a) je možné vidět dělení snímku na kvadranty, na obrázku (b) je zobrazeno dosažení homogenity oblastí a na (c) došlo ke spojení sousedních podobných oblastí.

Nevýhodou této metody je pravoúhlost segmentovaných oblastí a to především při větších tolerancích hodnocení homogenity [2].

3.3 Narůstání oblastí


Narůstání oblastí je další metoda segmentace založená na dělení obrazu do oblastí. Pixel je zařazen do potenciální oblasti a má tedy určen parametr p , který je typický pro danou oblast. Tímto parametrem může být například intenzita, lokální průměr nebo lokální rozptyl. Následně budou k tomuto pixelu (semínku) přiřazeny pixely okolní (vybírá se buď čtyřkolí, nebo osmiokolí), pokud splní kritérium homogenity. K porovnání parametrů p dochází podle vztahu

$$|p_s - p_j| \leq T, \quad (3.1)$$

kde p_s je hodnota adaptivního semínka, p_j hodnota parametru sousedních pixelů a T značí podmínku homogenity, tedy hodnotu určitého prahu. Pokud tato podmínka platí, můžeme sousední pixel přiřadit do dané oblasti, pokud ne, pak jej přiřadit nelze. Algoritmus končí jakmile semínko nemá kam růst. [1]

3.4 Metoda rozvodí

Tuto metodu lze pochopit s pomocí geologického modelu. Představme si, že jednotlivé hodnoty jasu představují výšku terénu a tedy se dá obraz rozdělit na vyvýšeniny a nížiny. V nížinách se vyskytují nejnižší body, kterými vtéká do nížin voda, která danou nížinu zaplňuje. Takto se to děje po celé ploše obrazu a v případě, že by mělo dojít k propojení zaplavených nížin, tak dojde k vybudování přehrady, která představuje hranici, mezi objekty, které ve skutečnosti v obrazu hledáme [7]. Segmentace neprobíhá s původním obrazem, ale s obrazem upraveným nejčastěji lokálními diferenčními operátory. Nevýhodou této metody bývá vznik velkého množství nížin, které nesouvisí s hledanými objekty, a proto se často po metodě rozvodí používá spojování oblastí, které pospojuje malé oblasti do větších [2]. Princip utváření přehrad lze vidět na obrázku 3.3.



Obr. 3.3: Schéma principu metody rozvodí na 1D řezu obrazem. Vzniklé přehrady tvoří výslednou segmentaci. [1]

3.5 Houghova transformace

Občas můžeme v obraze, který byl upraven hranovou detekcí, pozorovat hranice určitých objektů připomínající známé geometrické tvary jako jsou křivky, elipsy,

kružnice nebo složitější útvary. V tomto obraze jsou však tyto hranice většinou přerušované, nebo mohou být různým způsobem otočené, či jinak zdeformované. Proto nelze využít masku daného tvaru procházející obraz a hledat místo korelace. Řešením je Houghova transformace. Tato metoda hledá analytický popis hledaného tvaru v obraze [4]. Například při hledání přímky, kterou pojmenujeme p , a která je popsána rovnicí

$$x\cos\theta + y\sin\theta = n, \quad (3.2)$$

kde θ je úhel normály mezi hledanou přímkou p a počátkem soustavy x, y a n vzdálenost od středu. Zároveň jsou to hledané parametry. Pokud do dané rovnice přímky dosadíme souřadnice nějakého bodu, pak všechny řešení se promítnou do Houghova prostoru, jako spojitá křivka. Pokud si takto promítneme všechny pixely, tvořící hledanou přímku p , pak všechny přímky vzniklé v Houghově prostoru se protnou v jednom bodě, jejichž n a θ odpovídají parametrům hledané přímky p . [1].

3.6 Aktivní kontury

Aktivní kontury je metodou minimalizace energie splinu. Využívá se metody tzv. hada, kdy je využito přímky, která se postupně tvaruje tak, aby zaujala pozici s nejmenší energií, tedy aby se co nejvíce podobala hledanému tvaru [9]. Může se využít interakce s uživatelem. Uživatel určí přibližný tvar hledané kontury a také počáteční bod. Kontury jsou ovládány pomocí vnitřních a vnějších obrazových sil. Vnitřní síly ovlivňují tvarování kontury, aby byla co nejpodobnější hledané hraně a vnější síly jsou pak dány počáteční pozicí kontury. Pokud si definujeme konturu

$$v(s) = [x(s), y(s)], \text{ kde } s \in [0, 1], \quad (3.3)$$

pak můžeme její energii vyjádřit podle rovnice

$$E_s = \int_0^1 (E_N(v(s)) + E_I(v(s)) + E_T(v(s))) ds, \quad (3.4)$$

kde E_N , je vnitřní energie kontury, E_I energie obrazu a E_T energie omezení, kterou nastavuje uživatel. E_I a E_T společně definují vnější obrazové síly. Výsledná kontura se nachází na pozici, kde tato energie E_s dosahuje lokálního minima. [4]

3.7 Segmentace klasifikací pixelů

Segmentace klasifikací pixelů je metoda, při které se využívá prvotní úpravy obrazu, neboli získání příznaků. Může se využít hned několik metod, které byly zmíněny

v kapitole 1 . Tyto získané příznaky jsou následně klasifikovány pomocí klasifikátorů, jako jsou například ty zmíněné v kapitole 4 . Ty mají za úkol zpracovat velké množství příznaků a následně vyhodnotit, zda je pixel součástí některé z hledaných oblastí v obraze (jako například buňky), nebo naopak součástí oblasti další (například pozadí).

4 Klasifikátory

Klasifikátory slouží ke klasifikaci obrazu na základě získaných příznaků pomocí metod z kapitoly 1. Výstup Y může být klasifikován do několika tříd. My se budeme zabývat především binární klasifikací, kde rozlišujeme dvě třídy ω . Zpravidla je rozpoznáno pozadí (třída 0) a hledaná oblast (třída 1). Pokud však platí $\omega > 2$, pak se bavíme o klasifikaci s více třídami. Klasifikaci můžeme popsat také jako predikci. Kdy za použití trénovacího setu příznaků daný klasifikátor naučíme mapovat obraz a rozdělit jej do jednotlivých tříd a následně pak můžeme použít naučený klasifikátor na nová data, která mají podobný charakter, aby jej také rozdělil do tříd [15].


4.1 K-nejbližších sousedů

K-nearest neighbour (kNN) je jednoduchý neparametrický klasifikátor (usiluje tedy o co nejlepší přizpůsobení trénovacím datům, přičemž si zachovává schopnost zobecnění na doposud nepoužitá data), který jednoduše hledá K nejbližší body trénovacích dat D , které jsou nejbližší testovacím datům x . Následně spočítá kolik bodů dané třídy je v tomto setu a jako výstup vrátí odhad, do které třídy by x mohlo patřit [19]. Je důležité vybrat správnou hodnotu K , která by neměla být příliš malá ($K=1$, $K=2$), ale zároveň by neměla být ani příliš velká, jelikož by pak mohlo dojít k tomu, že by třída, která obsahuje pouze pár hodnot mohla být přehlasována ostatními třídami [16]. Také je vhodné volit lichou hodnotu K , abychom se vyhnuli remízám, kdy by se mohlo zdát, že x patří do dvou tříd [17]. Metodu lze popsat podle rovnice převzaté z [15].

$$P(Y = \omega|x, D, K) = \frac{1}{K} \sum_{i \in N_K(x, D)} \Gamma(Y_i = \omega), \quad (4.1)$$

kde $P(Y = \omega|x, D, K)$ je pravděpodobnost, že x patří do dané třídy ω , $N_K(x, D)$ jsou K nejbližší body k x v D , ω je číslo dané třídy a Γ je indikátorová funkce, která je rovna 1, pokud Y_i patří do ω a rovna 0 v opačném případě. Příkladem může být, že je nutné zařadit objekt \star do správné třídy (x,o). Parametr K je roven 5, tedy hledáme pět nejbližších okolních hodnot. Vzdálenost mezi \star a okolními body může být spočítána například jako euklidovská vzdálenost. Na obrázku 4.1 je vidět rozložení jednotlivých tříd.

Pokud tedy vypočítáme pravděpodobnost, že hledaný objekt patří do třídy x ($P(Y = \omega|x, D, K) = 4/5$), a pravděpodobnost, že patří do třídy o ($P(Y = \omega|x, D, K) = 1/5$), pak lze říci, že hledaný objekt patří s větší pravděpodobností do třídy x, tedy sem ho zařadíme[15].



Obr. 4.1: Přiřazení \star ke správné třídě při použití $K=5$

4.2 Náhodný les

Jako první je důležité si definovat, co je to rozhodovací strom (Decision tree). Rozhodovací strom je nelineární klasifikátor, jehož principem je multistupňové rozhodování, ve kterém jsou jednotlivé třídy odmítány, dokud nenarazí na třídu přijatelnou. Stromy obsahují uzly, ve kterých dochází k rozhodování o dané třídě. Často používané jsou rozhodovací stromy binární. V uzlech těchto stromů se nejčastěji rozhoduje na základě určeného prahu, tedy $x_k \leq \theta$, kde θ je daný práh. Výsledkem jsou pak dvě nové větve s daty $X_{t,Y}$ (odpověď ano) a $X_{t,N}$ (odpověď ne) [16]. Jelikož do stromu vstupuje N množství dat množiny X , tak x_k , kde $k = 1, 2, \dots, l$, může nabývat velkého množství různých hodnot. Proto počet takových otázek je roven $\sum_{k=1}^l N_{tk}$. Aby byl vytvořen nejlepší strom, je potřeba, aby bylo vybráno správné pořadí otázek v jednotlivých uzlech. Dále musí být splněno dělicí kritérium, které rozhodne, jak bude předeek rozdělen. Zároveň musí být zavedeno tzv. stop-splitting rule, které definuje ukončení růstu stromu a jeho dělení. Nakonec musí být konečné výsledky (listy) rozděleny do tříd. Výběr otázek závisí na rozhodovacím pravidle, jelikož je vybrána ta otázka, při které dojde k nejlepšímu rozdělení. Jako rozhodovací pravidlo se často používá tzv. Node impurity, které se vypočítá podle rovnice

$$I(t) = - \sum_{i=1}^M P(\omega_i|t) \log_2 P(\omega_i|t), \quad (4.2)$$

kde $I(t)$ je Node impurity, P je pravděpodobnost, že příznak ve větvi t patří do třídy ω_i , $i = 1, 2, \dots, M$. Následně se vybere ta otázka, která způsobí největší pokles Node impurity, vypočítaný podle rovnice

$$\Delta I(t) = I(t) - \frac{N_{tY}}{N_t} I(t_Y) - \frac{N_{tN}}{N_t} I(t_N). \quad (4.3)$$

Kde N_t je množství dat vstupujících do uzlu, N_{tY} je počet dat s odpovědí ano a N_{tN} naopak s odpovědí ne. Zastavení růstu stromu má dvě možnosti. Buď je zaveden nějaký práh T , a k dělení dojde pokud maximální hodnota $\Delta I(t)$ po všech děleních je méně než daný práh T , nebo pokud jsou jednotlivá data rozdělena tak, že patří každé do jedné třídy.

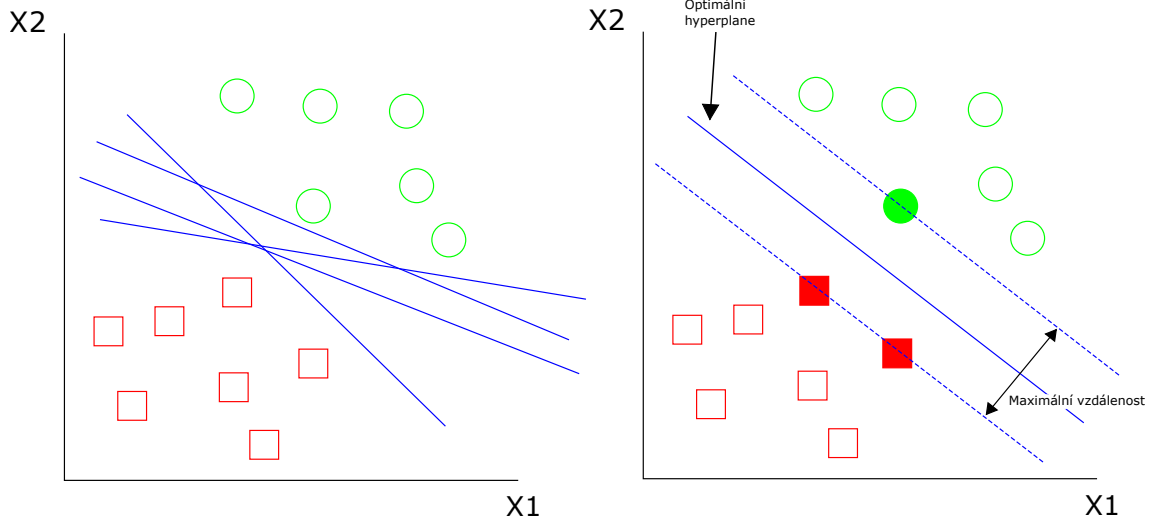
Jakmile je větev označena za list, tedy konečný prvek stromu, je mu přidělena třída. Ta je vybrána nejčastěji na základě pravidla většiny. Zpravidla danému listu přiřadíme tu třídu, do které patří většina z prvků [10]. Na jednu stranu jsou rozhodovací stromy jednoduché jak na vytvoření, tak i na interpretaci, na druhou stranu jsou však poněkud nepřesné. A to v případě, kdy je potřeba klasifikovat nová data. Proto se využívá metody náhodného lesa, která se skládá z velkého množství rozhodovacích stromů. Jako první je potřeba vytvořit tzv. bootstrap dataset, což znamená, že z dat, vytvoříme trénovací data pomocí náhodného vybírání s možným opakováním některých z nich. Při stavění rozhodovacích stromů již nevybíráme, který z příznaků je pro rozdělení dat nejlepší, ale opět dojde k náhodnému výběru např. dvou příznaků. Následně je zjištěno, který je nejlepší a ten je vybrán pro daný uzel. Takto náhodně je sestaven celý strom. Náhodný les však využívá nepřeberné množství takto náhodně sestavených rozhodovacích stromů. Nová data jsou pak otestována touto metodou a za výsledek je považováno to rozhodnutí, které dostalo nejvíce hlasů [15].

4.3 Metoda podpůrných vektorů

Metoda podpůrných vektorů, neboli SVM, je používána při klasifikaci, kdy optimálního výsledku je dosaženo, pokud je zvolena největší šířka tzv. diskriminační hyper roviny, která dané dvě třídy odděluje. Obecný princip SVM je vidět na obrázku 4.2. Vektory nacházející se nejbližší této rovině se nazývají podpůrné vektory, které specifikují danou diskriminační funkci. Obvykle existuje několik hyper rovin a je právě důležité vybrat tu nejvhodnější [16]. Pokud se zaměříme na případ lineárně rozdělitelných dat na dvě třídy a definujeme, že třídy $\omega \in -1, 1$ a hodnoty dat $x_i \in [0, 1]$, pak můžeme definovat hyper rovinu pro rozlišení daných tříd následovně [4]:

$$w \cdot x + b = 0, \quad (4.4)$$

Abychom maximalizovali šířku hyper roviny, definujeme paralelní hyper roviny:



Obr. 4.2: Snímek zobrazuje princip metody podpůrných vektorů. Nalevo je naznačen výběr tzv. hyper roviny. Napravo je již vybrána ta vyhovující hyper rovina.

$$w \cdot x + b = 1, \quad (4.5)$$

$$w \cdot x + b = -1, \quad (4.6)$$

procházející mezi podpůrnými vektory a nenacházejí žádné tréninkové vzorce. Aby mezi dvěma paralelními hyper rovinami opravdu nebyly tyto tréninkové vzorce, musíme pro každé x_i definovat:

$$\omega_i(w \cdot x_i + b) \geq 1. \quad (4.7)$$

Pokud x^+ je v pozitivní rovině a x^- nejbližší negativní, pak můžeme říct, že $x^+ - x^-$ je normála rovin, kterou označíme jako λ .

$$\begin{aligned} \lambda w &= x^+ - x^-, \\ \lambda \|w\|^2 &= x^+ \cdot w - x^- \cdot w, \\ \lambda \|w\|^2 &= 2 \end{aligned} \quad (4.8)$$

proto $|x^+ - x^-| = (\frac{2}{\|w\|})$. Abychom tedy maximalizovali šířku hyper roviny, musíme minimalizovat $\|w\|$, ale se splněním podmínky 4.7. Tohle může být vyřešeno speciální optimalizací kvadratického programování, po níž je hyper rovina umístěna mezi paralelní hyper roviny. Tato složitá optimalizace může být nahrazena Lagrangeovou funkcí:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i \omega_i(w_i \cdot + b) + \sum_{i=1}^N \alpha_i, \quad (4.9)$$

kde α jsou Lagrangeovy multiplikátory.

Pokud omezíme multiplikátory na $\alpha \geq 0$ a provedeme parciální derivaci předešlé rovnice s ohledem na w a b a položíme je rovny nule, pak získáme rovnice:

$$w = \sum_{i=1}^N \alpha_i \omega_i x_i, \quad (4.10)$$

$$\sum_{i=1}^N \alpha_i \omega_i = 0. \quad (4.11)$$

Pokud tyto vztahy použijeme pro vytvoření původní Lagrangerovy rovnice, pak vznikne tzv. duální formulace, kde se berou v úvahu tréninkové vzory x_i , x_j a jejich váhy ω_i a ω_j [4].

$$L(w, b, \alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j \omega_i \omega_j (x_i \cdot x_j), \quad (4.12)$$

kde $L(w, b, \alpha)$ musí být maximalizováno s podmínkami podle rovnice 4.11 a $\alpha_i \geq 0$ [18].

Pakliže není lineární rozdělení možné, využívá se kernelového triku. Můžeme nahradit x_i a x_j kernelovou (jádrovou) funkcí:

$$k(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j). \quad (4.13)$$

Myšlenkou tohoto je převedení dat do prostoru vyšší dimenze, ve které už je možné je lineárně rozdělit [10]. Samotný proces rozdělení je již podobný, jako při rozdělení lineárním, jen jsou všechny bodové funkce nahrazeny jádrovými funkcemi, na základě kterých jsou pak data lineárně rozdělena. Lagrangerova funkce po dosazení funkce jádrové vypadá následovně [4]:

$$L(w, b, \alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j \omega_i \omega_j k(x_i, x_j), \quad (4.14)$$

4.4 Naive Bayes

Tato metoda umožňuje klasifikovat vektory diskrétních funkcí $x \in 1, \dots, K^D$, kde K je počet příznaků pro každý prvek a D je počet prvků. Je potřeba, abychom udělali podmíněné rozdělení třídy, $p(x|y = c)$. Předpokládáme, že příznaky jsou podmíněně nezávislé vzhledem k dané třídě. Pak můžeme psát třídní podmíněnou hustotu jako produkt jednorozměrné hustoty podle následující rovnice převzaté z [10].

$$p(x|y = \omega, \theta) = \prod_{j=1}^D p(x_j|y = \omega, \theta_{j\omega}) \quad (4.15)$$

Metoda se nazývá naivní, protože se v praxi neočekává, že by příznaky byly nezávislé vzhledem k třídě. I když není tento předpoklad vždy splněný, tak naive Bayes je dobrým klasifikátorem. Hlavně kvůli tomu, že je velmi jednoduchý a je poměrně imunní vůči přetrénování. Forma, kterou lze hustotu vypočítat záleží na typu každého prvku. V případě prvků nabývajících reálných hodnot se používá Gaussovské rozdělení:

$$p(x|y = \omega, \theta) = \prod_{j=1}^D N(x_j|\mu_{j\omega}, \sigma_{j\omega}^2), \quad (4.16)$$

kde μ_{jc} je průměr znaku j v objektech třídy ω a $\sigma_{j\omega}^2$ je jeho odchylka. Pokud prvky nabývají pouze binárních hodnot, tak se využívá Bernoulliho rozdělení:

$$p(x|y = \omega, \theta) = \prod_{j=1}^D Ber(x_j|\mu_{j\omega}), \quad (4.17)$$

kde μ_{jc} je pravděpodobnost, že znak j patří do třídy ω . Samozřejmě je možné využít také jiných rozdělení. Co se týká trénování této metody, tak se budeme bavit o výpočtu MLE (Maximum Likelihood Estimation) pro naše parametry. Pravděpodobnost pro jeden prvek dat je dán rovnicí:

$$p(x_i, y_i|\theta) = p(y_i|\pi) \prod_j p(x_{ij}|\theta_j) = \prod_{\omega} \pi_{\omega}^{\Gamma(y_i=\omega)} \prod_j \prod_{\omega} p(x_{ij}|\theta_{j\omega})^{\Gamma(y_i=\omega)}, \quad (4.18)$$

proto můžeme zapsat tzv. log-likelihood jako:

$$\log p(D|\theta) = \sum_{\omega=1}^C N_{\omega} \log \pi_{\omega} + \sum_{j=1}^D \sum_{\omega=1}^C \sum_{i:y_i=\omega} \log p(x_{ij}|\theta_{j\omega}) \quad (4.19)$$

MLE můžeme vypočítat podle rovnice:

$$\hat{\pi}_{\omega} = \frac{N_{\omega}}{N} \quad (4.20)$$

Pokud chceme model použít pro predikci, pak musíme vypočítat:

$$p(y = \omega|x, D) \propto p(y = \omega|D) \prod_{j=1}^D p(x_j|y = \omega, D) \quad (4.21)$$


Za použití MLE pak vzorec vypadá takto:

$$p(y = \omega|x, D) \propto \hat{\pi}_{\omega} \prod_{j=1}^D (\hat{\theta}_{j\omega})^{\Gamma(x_j=1)} (1 - \hat{\theta}_{j\omega})^{\Gamma(x_j=0)}, \quad (4.22)$$

kde $\hat{\theta}$ je MLE parametrů θ [18].

4.5 Neuronové sítě

Neuronové sítě jsou považovány za nelineární systémy s více vstupy a jedním nebo více výstupy. Obecný vzhled takovéto sítě lze vidět na obrázku 4.3. Jako vstup bývá nejčastěji vektor reálných nebo binárních čísel. Následně jsou mapovány na výstupní vektory ($x \rightarrow y$) často binárních, ale i reálných čísel. Samotné mapování je různé pro různé druhy neuronových sítí a záleží na parametrech dané sítě. Těmito parametry jsou váhy, které jsou časově variabilní, tedy v průběhu mapování dochází k průběžnému přepočítávání. K samotnému mapování dochází při průběhu učení neuronové sítě. V podstatě existují dva druhy neuronových sítí a to s neuronové sítě s učitelem a bez učitele. Neuronové sítě s učitelem vyžadují, aby pro vstupní vektor x_k byl znám výstupní vektor y_k . Skutečný výstup se pak lehce liší od vektoru y_k . Během mapování dochází ke konvergentnímu přibližování se k výsledku, nebo spíše jeho přibližné hodnotě. Neuronové sítě bez učitele se používají tehdy, když není znám výstup mapování a mělo by být automaticky odvozeno od vektoru vstupního. Neuronové sítě se skládají z jednotlivých neuronů, které provádí jednoduché úkony:



Obr. 4.3: Obrázek zobrazuje obecný princip a skladbu neuronové sítě.

$$y = f\left(\sum_{i=0}^N w_i x_i\right) = f(\mathbf{w}^T \mathbf{x}) = f(\alpha), \quad (4.23)$$

kde x je vstupní vektor neuronu, w je vektor vah, y požadovaný výstup a $f(\alpha)$ je aktivační funkce neuronu. Tento výpočet je stejný ve všech neuronových sítích [1]. Záleží také na druhu aktivační funkce, což může být např. funkce lineární, skoková nebo sigmoidální [16]. Aktivační funkce ovlivňuje typ výstupního vektoru, kdy při skokové je výstup binární $\{0; 1\}$ a například u lineární pak $y \in \langle -\infty; \infty \rangle$.


Jak už bylo zmíněno, v průběhu mapování dochází k průběžnému přepočítávání vah a to pomocí očekávaného výstupu y_d a aktuálního výstupu y pomocí tzv. δ – pravidla:

$${}_{n+1}w = {}_n w + \mu(y_d - y)x. \quad (4.24)$$


Zde je μ konstanta, která ovlivňuje rychlost přibližování se k výsledku [1]. Existuje hned několik architektur neuronových sítí. Neuronová síť se zpětnou propagací (Feedforward neural networks) mají pouze jednosměrný tok informací, tedy ze vstupní vrstvy jde informace do druhé vrstvy a tak dále až po vrstvu výstupní. Váhy jsou přepočítávány pomocí chyby zpětného šíření (back-propagation) $e_k =_d y_k - y_k$. Takto se vypočítá chyba pro všechny neurony. Jakmile je známá místní chyba, tak může dojít k přepočítání vektoru vah w pomocí δ – pravidla. Průchod všech trénovacích vektorů x se nazývá učící epocha. Pokud se neuronová síť nedokáže přizpůsobit trénovacím datům dostatečně rychle, tak je potřeba provést několik epoch, ale je potřeba si dát pozor na přetrénování sítě, což může být způsobené velkým počtem epoch. [4].

5 Dataset


V tomto datasetu jsou obsaženy snímky buněk z linie PNT1A, což je epiteliální buňková linie odvozená z lidských nenádorových buněk prostaty, které byli zachyceny pomocí více druhů mikroskopů bez použití značení. Dále je v datasetu obsažena ručně vytvořená anotace, pro následné použití v algoritmech segmentace. Samotné buňky byly kultivovány v médiu RPMI-1640 doplněné antibiotiky jako je penicilin (100U/ml) a streptomycin (0,1mg/ml) s 10% fetálním hovězím sérem. Před získáním snímků byly buňky uschovány při teplotě 37°C v inkubátoru s 5% CO_2 . Byl použit vysoký počet buněk, aby se popsala morfologická heterogenita buněk (buňky zaoblené, vřetenovité, malé a velké polyploidní buňky). Mikroskopie pro kvantitativní fázové zobrazování (QPI) byla provedena na přístroji Tescan Q-PHASE, s objektivem Nikon CFI Plan Fluor 10x/0,30 zachyceným Ximea MR4021MC. Zobrazování je založené na konceptu holografického mikroskopu řízeného koherencí. Tyto obrázky jsou zobrazeny v odstínech šedé a jejich rozměry jsou 600×600 pixelů. Díky menšímu rozměru obsahují také menší počet buněk, než snímky ostatní. DIC mikroskopie byla provedena na mikroskopu Nikon A1R, s objektivem Nikon CFI Plan Apo VC 20x/0,75 zachyceným CCD kamerou Jenoptik ProgRes MF a jejich rozměry jsou 1360×1024 pixelů. HMC mikroskopie byla prováděna na mikroskopu Olympus IX71, s objektivem Olympus CplanFL N 10x/0,3 RC1 zachyceným CCD kamerou Hamamatsu Photonics ORCA-R2. HMC snímky mají rozměry 1344×1024 pixelů. Snímky PC mikroskopie byly zachyceny na mikroskopu Nikon Eclipse TS100.F, s objektivem Nikon CFI Achro ADL 10x/0,25 zachyceným CCD kamerou Jenoptik ProgRes MF a jejich rozměr je stejný, jako u snímků DIC, tedy 1360×1024 pixelů.




(a) Snímek DIC mikroskopu



(b) Snímek HMC mikroskopu



(c) Snímek PC mikroskopu



(d) Snímek QPI mikroskopu

Obr. 5.1: Na těchto obrázcích jsou zobrazeny výřezy mikroskopických snímků DIC,HMC, PC a QPI o velikosti 451x451 pixelů s upraveným kontrastem pro lepší viditelnost.

6 Vyhodnocení výsledků

Pro hodnocení segmentace byly vybrány tři statistické údaje a to: senzitivita, dice a pozitivní prediktivní hodnota. Senzitivitu můžeme popsat jako sílu modelu predikovat pozitivní výstup, určuje tedy kolik pixelů klasifikátor správně klasifikoval. Dice (DSC) slouží k měření podobnosti vzorků a pozitivní prediktivní hodnota (PPH) měří pravděpodobnost, že daný pixel má ve skutečnosti stejnou hodnotu, jako hodnota, která mu byla přiřazena klasifikátorem. [23]. Můžeme je vypočítat pomocí následujících vzorců po získání hodnot skutečně pozitivních (TP), skutečně negativních (TN), falešně pozitivních (FP) a falešně negativních (FN).

$$\text{Senzitivita} = \frac{\sum TP}{\sum TP + \sum FN} \quad (6.1)$$


$$DSC = \frac{2 \sum TP}{2 \sum TP + \sum FP + \sum FN} \quad (6.2)$$

$$PPH = \frac{\sum TP}{\sum TP + \sum FP} \quad (6.3)$$


Pro hodnocení výsledků byla důležitá také k-násobná křížová validace, kdy vždy například z jedenácti snímků byl klasifikátor naučen na prvních deseti snímcích a jedenáctý byl použit jako validační. V dalším cyklu byl naučen na 2.-11. snímku a první byl použit jako validační. Takto došlo k postupnému využití všech obrazů k validaci a následně byl výsledek vypočítán jako průměr průběžných výsledků.

6.1 Implementace vybraných klasifikátorů

Aby bylo možné statisticky vyhodnotit vhodnost použitých příznaků, bylo potřeba prvně vybrat klasifikátor, pomocí kterého bylo možné tyto příznaky porovnat. Na základě literární rešerše jsem vybral tři klasifikátory, kterými jsou náhodný les, SVM a K-nejbližších sousedů (kNN). Vybral jsem právě tyto klasifikátory, jelikož jsou poměrně jednoduché a zároveň se vyskytují v několika odborných článcích zabývajících se podobnou problematikou [33]. Při vstupu příznaků do klasifikátoru bylo nutné vybrat pouze určitou část pixelů, aby došlo ke snížení výpočetní náročnosti. Zde bylo zvoleno 5% z vytvořených vzorků, které byly vždy náhodně vybírány. Z obrázků 6.1a a 6.1b lze pozorovat, že 5% je dostačujících, jelikož nad tento počet již nedochází k markantním změnám, což je způsobené tím, že sousední pixely jsou korelované a tedy nepřinášejí informaci navíc.



(a) Snímek s 5% pixelů



(b) Snímek s 20% pixelů

Obr. 6.1: Porovnání snímků s různým množstvím pixelů

Podle přiložené tabulky 6.1 můžeme pozorovat výsledky pro jednotlivé klasifikátory.

Tab. 6.1: Tabulka porovnání výsledků klasifikátorů, ze kterých lze vidět, že náhodný les dosahuje výsledků nejlepších.


	Náhodný les			SVM	K-nejbližších sousedů		
	10 stromů	50 stromů	100 stromů	RBF	k=5	k=15	k=35
DSC [%]	71,04	71,29	72,29	70,53	69,4	72,11	72,19
Senzitivita [%]	72,13	73,38	73,36	66,11	70,02	72,32	72,42
PPH [%]	70,92	71,03	71,65	73,6	68,25	70,46	72,34

Metody K-nejbližších sousedů a Náhodný les dosahují podobně dobrých výsledků. Metoda podpůrných vektorů dosahuje hodnot nižších, v porovnání s nejlepšími výsledky již zmíněných klasifikátorů, avšak taky ne špatných. Pro následné vyhodnocení výsledků pro jednotlivé příznaky byl použit Náhodný les, jelikož dosahuje výsledků nejlepších, že všech porovnávaných klasifikátorů.

6.2 Vyhodnocení použití samostatných příznaků

Při zpracování obrazu bylo pro bakalářskou práci nejprve využito pouze jednoho druhu snímků a to těch, které byli vytvořeny pomocí DIC mikroskopie. Na snímku 6.2a můžeme vidět původní obraz, ze kterého byly vytvořeny příznaky a 6.2b je pak obraz referenční, který vstupoval společně s příznaky do klasifikátoru. Na základě lineární rešerše byly pro segmentaci vybrány příznaky z oblasti texturní analýzy a to

jsou determinant Hessianovy matice, Gaborův filter a matice délek běhů (RL matice). Mimo texturní analýzu byly použity ostřicí masky 6.4,



(a) Původní snímek

(b) Referenční snímek pro klasifikaci

Obr. 6.2: Na obrázku (a) můžeme vidět původní DIC snímek, který byl následně upravován a na snímku (b) je referenční maska, která také vstupuje do klasifikátoru.


$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}, \begin{bmatrix} -1 & -1 & -1 \\ -1 & 11 & -1 \\ -1 & -1 & -1 \end{bmatrix}, -\frac{1}{2} \begin{bmatrix} 1 & 1 & 1 \\ 1 & -10 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad (6.4)$$

kteřé měly také poměrně dobré statistické výsledky, jak je vidět z tabulky 6.2. Mají poměrně dobré procento senzitivity, avšak podle pozitivní prediktivní hodnoty lze vidět, že spousta pixelů nebylo klasifikováno správně.

Tab. 6.2: Tabulka porovnání výsledků jednotlivých příznaků ostřících masek

	Ostřicí maska 1	Ostřicí maska 2	Ostřicí maska 3
DSC [%]	33,6	33,6	27,6
Senzitivita [%]	26,6	26,9	21,7
PPH [%]	52,63	51,6	46,2

Tabulka 6.3 zobrazuje výsledky příznaků texturní analýzy, které měly poněkud lepší výsledky, než použité konvoluční masky. Determinant Hessianovy matice si vedl nejlépe, a to hned ve všech třech statistických údajích, a tedy je nejprínosnějším příznakem pro segmentaci, dále Gaborův filtr, který byl použit ve směrech 45° a 90° si vedl také velmi dobře. Pokud se však podíváme na matici délek běhů, tak výsledky jsou až na senzitivitu velmi špatné, což znamená, že velké množství pixelů,



(a) 1.Ostřicí maska

(b) 2.Ostřicí maska

(c) 3.Ostřicí maska

Obr. 6.3: Snímky příznaků vytvořených ostřicími maskami 6.4

bylo klasifikováno špatně, jako pozadí. Proto je tento příznak nejméně přínosný a to i v porovnání s využitými konvolučními maskami.

Tab. 6.3: Tabulka porovnání výsledků jednotlivých příznaků texturní analýzy


	determinant Hesovy matice	Gaborův filtr 45°	Gaborův filtr 90°	Matice délek běhů
DSC [%]	53,56	51,2	48,9	6
Senzitivita [%]	57,4	55,3	52,9	3,1
PPH [%]	52,8	50,8	48,7	90,8

Z přiložených snímků 6.4a,6.4b a 6.4c je vidět, proč jsou tyto příznaky považovány za velmi dobré. Je to kvůli tomu, že samotné jsou schopné obraz nasegmentovat poměrně dobře. Naopak snímek 6.4d ukazuje, že matice délek běhů není až tak přínosný příznak, jelikož jako pixely buněk je klasifikováno správně pouze malé množství.


Dále byly použity také příznaky z oblasti detekce hran. Byl použit Sobelův operátor, operátor Prewittové a Laplacián gaussianu, jejichž výsledky segmentace je možné vidět v tabulce 6.4.

Tab. 6.4: Tabulka obsahuje statistické výsledky operátorů pro detekci hran, které byly samostatně použity pro segmentaci obrazu snímku DIC.


	Sobelův operátor	Operátor Prewittové	Laplacián gaussianu
DSC [%]	22,20	22,90	29,93
Senzitivita [%]	12,95	13,41	19,73
PPH [%]	86,28	86,33	67,12




(a) Gaborův filtr ve směru 45°



(b) Gaborův filtr ve směru 90°



(c) Determinant Hessianovy matice



(d) Matice délek průběhů

Obr. 6.4: Snímky segmentovaného obrazu pomocí příznaků z texturní analýzy

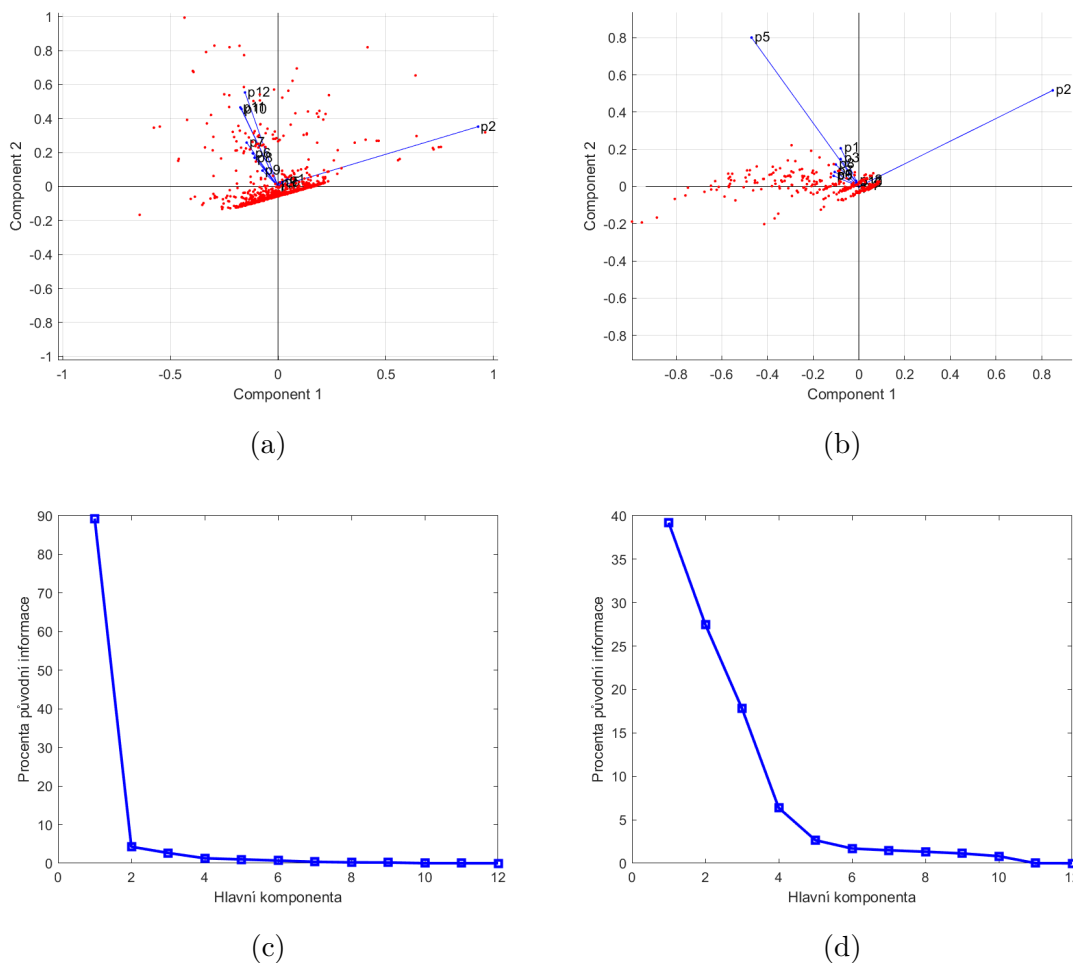
6.3 Výběr a vyhodnocení podmnožin příznaků

Výsledné podmnožiny byly vybírány z dvanácti příznaků, kterým bylo přiřazeno jejich pořadové číslo podle tabulky 6.5. Vždy byly vytvořeny dvě podmnožiny pomocí dopředné metody a dvě podmnožiny metodou mRMR. Podmnožin je vytvořeno více, jelikož jsou vypočítávány na základě 10% pixelů, které jsou vybírány náhodně a křížová validace byla provedena pouze se čtyřmi snímky, aby proces nebyl příliš časově náročný, tudíž může docházet k drobným odchylkám, které se projeví v drobných rozdílech mezi množinami. I přes snahu snížit výpočetní náročnost trval výběr podmnožiny dopřednou metodou okolo čtyř hodin a metodou mRMR okolo tří a půl hodin. V následující části jsou zmíněny pouze tabulky podmnožin příznaků s nejlepšími výsledky, zbylé tabulky jsou zaznamenány v příloze A.

Tab. 6.5: Seznam použitých příznaků pro klasifikaci

1.Ostřící maska	1.
2.Ostřící maska	2.
3.Ostřící maska	3.
Determinant Hessianovy matice	4.
Matice délek běhů	5.
Gaborův filtr ve směru 0°	6.
Gaborův filtr ve směru 45°	7.
Gaborův filtr ve směru 90°	8.
Gaborův filtr ve směru 135°	9.
Sobelův operátor	10.
Operátor Prewittové	11.
Laplacián gaussianu	12.

Pro hodnocení jejich výsledku byly opět zvoleny metriky DSC (F1-skóre), která je považována za rozhodující v určení kvality segmentace obrazu, pozitivní prediktivní hodnota (PPH) a senzitivita. Všechny vybrané podmnožiny byly následně klasifikovány pomocí náhodného lesa, u kterého bylo primárně zvoleno sto a dvě sta rozhodovacích stromů, k-nejbližších sousedů s různými hodnotami koeficientu k a SVM klasifikátoru s polynomiálním kernelem, jehož stupeň ovlivňuje zakřivení podpůrných vektorů a rbf (radial basis function) kernelem s různým koeficientem γ , který definuje jak daleký je dosah vlivu jednotlivých pixelů v jejich okolí. Dále byl u obou druhů SVM nastaven parametr box constraint, který ovlivňuje počet vytvořených podpůrných vektorů.



Obr. 6.5: Na snímku (a) je zobrazen PCA biplot modality DIC. V (b) je zobrazen PCA biplot snímku QPI. (c) zobrazuje kolik procent informace obsahuje každá z hlavních komponent pro modalitu DIC a (d) pak pro modalitu QPI.

Jen pro ukázkou byla provedena analýza hlavních komponent pro snímky QPI a DIC. Snímek 6.5a zobrazuje PCA biplot pro modalitu QPI a snímek 6.5b pro modalitu DIC. Na těchto biplotech jsou původní příznaky reprezentovány modrými přímkami, které popisují vztah příznaků mezi sebou a zároveň vliv příznaků na jednotlivá hlavní komponenta. Tím, že mezi sebou přímky svírají malý úhel se vysvětluje velká korelace mezi těmito příznaky. Velký vliv na komponentu jedna, má, pro modalitu QPI, příznak $p2$. Na komponentu dva pak například příznaky $p10$ a $p12$. Grafy 6.5c a 6.5d ukazují, kolik procent původní informace obsahuje každá z hlavních komponent. Pro modalitu QPI by pak stačilo využít první dvě komponenta, pro modalitu DIC spíše první tři, jelikož první dvě neobsahují dostatečně velké množství původní informace.

6.3.1 Podmnožiny vybrané dopřednou metodou

Výsledky jsou shrnuty do několika tabulek rozdělených podle použitých snímků a obsahují vždy výsledky pro vhodnější podmnožinu. V tabulce 6.6 jsou shrnuty výsledky pro mikroskopické snímky DIC. Jsou zde výsledky pro množinu příznaků, která se skládá z Gaborova filtru ve směru 45° , 90° a 135° , 2. ostřicí masky, Sobelůva operátoru a operátoru Prewittové. Výsledky dosahují lehce nad hranici 70%. Nejlepší výsledky byly vyhodnoceny klasifikátorem k-nejbližších sousedů s koeficientem $k = 35$. Tento klasifikátor také vyhodnotil výsledky nejrychleji a to během 45 minut. Náhodný les s 200 rozhodovacími stromy vyhodnotil výsledek za necelé čtyři hodiny a například SVM s rbf kernelem pak za hodin osmnáct.

Tab. 6.6: Tabulka shrnuje výsledky vybrané podmnožiny příznaků dopřednou metodou pro snímek typu DIC. Nejlepšího výsledku dosahuje klasifikátor k-nejbližších sousedů.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
DSC [%]	71,76	72,03	72,32	72,59	23,38	71,63
Senzitivita [%]	74	74,15	73,94	74,15	22,90	66,28
PPH [%]	70,82	71,20	71,89	72,23	21,88	78,48

Výsledky pro snímky typu HMC jsou shrnuty v tabulce 6.7. V podmnožině jsou tyto příznaky: Gaborovy filtry ve směrech 0° , 45° , 90° a 135° , determinant Hessovy matice a 2. ostřicí maska. V případě tohoto snímku se výsledky pohybují v rozmezí 71-75%. Nejlepším z klasifikátorů je náhodný les se 100 rozhodovacích stromů s výsledkem $DSC = 75,29\%$. Z časového hlediska však byl nejlepší klasifikátor k-nejbližších sousedů, jehož výsledek je jen o 0,29% horší, avšak vyhodnocení bylo o dvě hodiny rychlejší. Ačkoli SVM s rbf kernelem dosahuje také vysokých hodnot DSC, tak zde je opravdu potřeba zohlednit trvání klasifikace, která se pohybovala okolo osmnácti hodin.

Snímky s kvantitativní fází zobrazování (QPI), vyhodnocené v tabulce 6.8, dosahují nejlepších výsledků ze všech druhů snímků a to okolo 90%. Podmnožina příznaků obsahuje ostřicí masky 1., 2. a 3., matici délek běhů a Gáborovy filtry ve směru 0° a 135° . Jako nejlepší klasifikátor se jeví k-nejbližších sousedů a to s výsledkem $DSC = 92,40\%$. Zároveň byl tento klasifikátor také nejrychlejší ve vyhodnocení výsledku.

Tab. 6.7: Tabulka shrnuje výsledky vybraných podmnožin příznaků dopřednou metodou pro snímek typu HMC. Náhodný les je klasifikátor s nejlepšími výsledky.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
9,6,7,8,4,2						
DSC [%]	75,29	74,92	74,75	75,00	24,58	75,18
Senzitivita [%]	76,97	73,29	76,57	76,94	23,28	70,69
PPH [%]	74,05	74,51	73,44	73,59	22,39	76,72

Tab. 6.8: Tabulka shrnuje výsledky vybraných podmnožin příznaků dopřednou metodou pro snímek typu QPI. Nejlepší klasifikátor je tady k-nejbližších sousedů.


Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
5,3,2,1,9,6						
DSC [%]	92,34	91,33	92,37	92,40	44,64	91,74
Senzitivita [%]	94,11	93,72	93,14	93,20	60,40	93,29
PPH [%]	90,88	89,97	91,67	91,68	55,77	90,31

Snímky z mikroskopie s fázovým kontrastem (PC) dosahují nejhorších výsledků, jelikož se pohybují těsně kolem hranice 70%, jak je možné pozorovat z tabulky 6.9. Podmnožina příznaků použitá pro klasifikaci se skládá z Gaborových filtrů ve směru 45° a 90°, determinantu Hessovy matice, 1. a 3. ostřicí masky a Sobelova operátoru pro detekci hran. Nejlepším klasifikátorem zde byl náhodný les s 200 rozhodovacími stromy, který měl DSC rovno 71,30%. Čas vyhodnocení byl opět okolo čtyř hodin a i když byl kNN o více než tři hodiny rychlejší, jeho výsledky dosahují pouze nad hranici 65%.

V grafu 6.6 lze pozorovat, že modalita QPI dosahuje výsledků nejlepších, a to nad 90%. Segmentovaný snímek QPI byl tedy podle výsledků na 92,40% podobný, jako reference. Na základě senzitivity, která je rovna 93,20%, je možné říci, že 6,80% pixelů, klasifikovaných jako pozadí jsou ve skutečnosti pixely buňky. Naopak podle pozitivní prediktivní hodnoty, která vyšla 91,68%, je zřejmé, že 8,32% pixelů kla-

Tab. 6.9: Tabulka shrnuje výsledky vybraných podmnožin příznaků dopřednou metodou pro snímek typu PC. Náhodný les dosahuje nejlepších statistických výsledků.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
7,8,4,1,3,10						
DSC [%]	70,66	71,30	65,52	65,37	21,89	64,05
Senzitivita [%]	66,02	67,19	60,06	59,79	21,09	56,21
PPH [%]	76,40	76,34	72,65	72,71	20,87	75,18



Obr. 6.6: Graf zobrazuje nejlepší dosažené výsledky, pro použité mikroskopické modalitty, dopředné metody.

sifikovaných jako pixely buňky jsou pixely pozadí. Ostatní modalitty tak úspěšnou segmentaci nemají, jelikož u DIC, HMC i PC modalit se DSC pohybuje nad hranicí 70%. U snímků DIC a HMC je senzitivita vyšší, než pozitivní prediktivní hodnota, tedy je více špatně klasifikovaných pixelů buněk, než pixelů pozadí. U snímků PC modalitty to je přesně naopak.

6.3.2 Podmnožiny vybrané metodou mRMR

Tyto podmnožiny příznaků byly vybrány na základě vztahu jednotlivých příznaků s referenčním snímkem (relevance) a vztahem mezi příznakem a již vybranými pří-

znaky (redundance). Podmnožiny příznaků pro snímky s diferenciálním interferenčním kontrastem (DIC) jsou vyhodnoceny v tabulce 6.10. Podmnožina obsahuje Gaborovy filtry ve směru 0° a 90° , matici délek běhů a operátor Sobelův, Prewittové a Laplacián gaussianu. Tato podmnožina dosahuje nejlepších výsledků pro náhodný les se 100 rozhodovacích stromů. Náhodný les s 200 rozhodovacími stromy dosahuje zanedbatelně rozdílných výsledků, ale jelikož je časově náročnější, tak není řazen mezi nejlepší. Naopak k -nejbližších sousedů s koeficientem $k = 35$ má výsledek také velmi dobrý a zároveň má nízkou časovou náročnost.

Tab. 6.10: Tabulka shrnuje výsledky vybraných podmnožin příznaků metodou mRMR pro snímek typu DIC. Velmi dobrých výsledků dosahuje náhodný les s 100 i 200 stromy.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
DSC [%]	72,11	72,10	71,77	71,97	21,83	70,54
Senzitivita [%]	73,10	73,05	73,00	73,27	20,72	66,11
PPH [%]	72,83	72,87	72,25	72,40	21,63	76,43

Tabulka 6.11 shrnuje výsledky pro snímky HMC. Mezi příznaky v této množině je Gaborův filtr ve směru 90° . Jako další obsahuje podmnožina všechny operátory pro detekci hran, tedy Sobelův, Prewittové a Laplacián gaussianu, dále matici délek běhů a jako poslední 3. ostřicí masku. Jako nejlepší byla vyhodnocena klasifikace náhodným lesem s 200 stromy a to $DSC = 72,92\%$. Ostatní klasifikátory měly výsledky horší o jedno a více procent.

Statistické výsledky snímků QPI v tabulce 6.12 dosahují hodnot nad 90%. Jako vhodnější byla vybrána podmnožina obsahující všechny tři operátory pro detekci hran, matici délek běhů, Gaborův filtr ve směru 45° a 2. ostřicí masku. Nejlepších výsledků zde dosahuje klasifikátor k -nejbližších sousedů s koeficientem $k = 35$ a to $DSC = 92,10\%$. Tento klasifikátor byl také časově nejméně náročný, jelikož klasifikace opět probíhala okolo 45 minut.

Dále byly metodou mRMR vybrány podmnožiny pro snímky s fázovým kontrastem (PC). Vhodnější metoda obsahuje opět všechny tři operátory pro detekci hran, 3. ostřicí masku, matici délek běhů a Gaborův filtr ve směru 135° . Suverénně nejlepších výsledků dosahuje klasifikátor kNN s koeficientem $k = 25$ a to $DSC = 65,67\%$, který byl zároveň časově nejméně náročný.

Výsledky této metody, hledání podmnožiny příznaků, jsou shrnuty do grafu 6.7. Modalita QPI dosahuje opět nejlepších výsledků. Modalita HMC, DIC a PC mají

Tab. 6.11: Tabulka shrnuje výsledky vybraných podmnožin příznaků metodou mRMR pro snímek typu HMC. Klasifikátor s nejlepšími výsledky je náhodný les.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
8,10,11,5,12,3						
DSC [%]	71,50	72,92	71,31	71,30	22,89	71,95
Senzitivita [%]	70,05	71,29	70,58	70,04	22,50	65,79
PPH [%]	73,76	73,51	73,18	73,35	21,11	75,75


Tab. 6.12: Tabulka shrnuje výsledky vybraných podmnožin příznaků metodou mRMR pro snímek typu QPI. Nejlépe klasifikoval klasifikátor k-nejbližších sousedů.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
2,5,11,10,12,7						
DSC [%]	91,60	90,62	91,67	92,10	43,87	91,12
Senzitivita [%]	91,82	90,54	92,06	92,16	58,91	92,03
PPH [%]	91,56	90,79	91,36	92,11	53,99	90,56

Tab. 6.13: Tabulka shrnuje výsledky vybraných podmnožin příznaků metodou mRMR pro snímek typu PC. K-nejbližších sousedů dosahuje nejlepších výsledků pro tuto modalitu.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
9,5,10,11,12,3						
DSC [%]	63,14	62,48	65,67	63,57	20,12	59,48
Senzitivita [%]	57,13	53,22	61,64	57,02	19,92	48,91
PPH [%]	71,60	76,00	70,75	72,43	18,35	75,62

výsledky pohybující se okolo hranice 70%. Tedy podle hodnoty DSC je možné říci, že segmentace snímků DIC je na 72,11% podobná referenci, HMC potom na 72,92% a PC pouze na 65,67%.



Obr. 6.7: Graf zobrazuje nejlepší dosažené výsledky, pro jednotlivé mikroskopické modality, metody mRMR.

7 Diskuze výsledků

V této kapitole jsou diskutovány jednotlivé výsledky a účinnost vybraných příznaků a klasifikátorů použitých pro různé mikroskopické modalitty.

7.1 Výběr příznaků

Pro segmentaci mikroskopických snímků bylo vybíráno z dvanácti příznaků. Z oblasti lokálních operátorů byly použity tři ostřicí masky a tři operátory pro detekci hran. Další příznaky byly vybrány z texturní analýzy a jedná se o determinant Hessovy matice, Gaborův filtr ve směrech 0° , 45° , 90° a 135° a jako poslední pak matice délek běhů. Některé z těchto příznaků byly použity i v semestrální práci a bylo zjištěno, že samotné jsou schopny poměrně úspěšně obraz segmentovat. Operátory pro detekci hran byly přidány i přes to, že nedosahují tak dobrých výsledků, jako ostatní příznaky, což je vidno z tabulky 6.4, ale jelikož při segmentaci je většinou problém, že buňky nejsou z velké části segmentovány právě u hran, tak by tyto operátory mohly pomoci k lepšímu vizuálnímu výsledku.

Pro uspokojivé výsledky však není samotný příznak dostačující, a proto bylo vybráno několik podmnožin příznaků, které se společně na segmentaci podílely. Metody použité pro výběr těchto podmnožin příznaků byly dopředná metoda, vysvětlená v kapitole 2 a metoda minimální redundance a maximální relevance, tedy metoda mRMR, vysvětlená taktéž v kapitole 2. Pomocí obou metod byly vytvořeny dvě podmnožiny pro každou z mikroskopických modalit, jelikož kvůli výpočetní náročnosti byly provedeny určité změny, kvůli kterým mohlo dojít k menším odchylkám. V podkapitole 6.3 jsou zmíněny pouze podmnožiny dosahující nejlepších výsledků pro obě metody. Tabulky s dalšími výsledky jsou v příloze A. Dopřednou metodou byly ve většině případů vybrány příznaky z oblasti texturní analýzy a ostřicí masky, což může být způsobeno tím, že sestavení podmnožiny bylo provedeno na základě výpočtu DSC, tedy F1-skóre, a tak byl pouze porovnáván vztah segmentovaného obrazu vytvořeného daným souborem příznaků s referenčním snímkem. U metody mRMR je možné si naopak všimnout, že ve všech vybraných souborech příznaků vystupují příznaky vytvořené detekcí hran, které jsou následně doplněné kombinací příznaků vytvořených ostřicími maskami a texturní analýzou. To může být způsobené tím, že kromě vztahu příznaku s referenčním snímkem se u této metody také klade důraz na vztah s již vybranými příznaky. Časově náročnější je metoda dopředná, která ale dosahuje lepších výsledků pro všechny modalitty. V případě snímků PC je to o necelých 5%. Proto je jako vhodnější metoda pro výběr podmnožiny příznaků zvolena právě metoda dopředná, jejíž nejlepší výsledky jsou shrnuty v grafu 6.6.


7.2 Výběr klasifikátorů

Nezbytnou součástí segmentace obrazu bylo v tomto případě využití klasifikátoru, který klasifikoval jednotlivé pixely vytvořených příznaků. Následně byl porovnáván segmentovaný obraz s referenčním, díky čemuž bylo možné statistické vyhodnocení klasifikace. Jako hlavní statistická metoda bylo vybráno DSC, kvůli jeho použití při vytváření podmnožin příznaků dopřednou metodou. Z několika možností klasifikátorů byly vybrány tři. Náhodný les, K-nejbližších sousedů a metoda podpůrných vektorů, neboli SVM. U náhodného lesa bylo nastavováno pouze množství rozhodovacích stromů. V tabulkách z podkapitoly 6.3 jsou vypsány výsledky pro sto a dvě sta stromů, jelikož to byly výsledky nejlepší. U metody nejbližších sousedů byl měněn koeficient k , a to na hodnoty 5, 15, 25, 30 a 35. Ve výsledcích jsou zmíněny hodnoty k rovny 25 a 35, jelikož tyto parametry dosahovaly opět nejlepších výsledků. U SVM byly nastavovány typy kernelovské funkce a tzv. box constraint. Byla použita funkce polynomiální a funkce radiální báze (RBF). U polynomu byl zvolen stupeň 5 a 2, ale ve výsledných tabulkách je pouze zaznamenán polynom 2. stupně, jelikož u pátého stupně byly výsledky v některých případech až o 15% nižší, než u stupně druhého. U RBF byla nastavována hodnota konstanty gama na hodnoty $\gamma = 0,5$ a $\gamma = 10$. Zároveň byl měněn parametr box constraint na hodnoty 5 a 100. Jelikož se výsledky lišily jen minimálně, tak v tabulce výsledků je vybráno jen jedno nastavení, a to $\gamma = 0,5$ a box constraint s hodnotou 5. Další nastavení klasifikátorů je ve vybraných výsledcích v příloze A. Při hodnocení efektivity použitých klasifikátorů je potřeba se dívat také na dobu klasifikace. Z tohoto hlediska je rozhodně nejlepší klasifikátor K-nejbližších sousedů, jelikož průměrný čas klasifikace se pohybuje okolo čtyřiceti pěti minut. Na druhém místě je náhodný les, jehož doba klasifikace se pohybovala okolo čtyř hodin a na posledním místě je pak SVM, který klasifikoval v průměru 18 hodin. Pokud tedy vezmeme v potaz statistické výsledky a čas potřebný pro klasifikaci s křížovou validací, jako nejefektivnější klasifikátor je vyhodnocen rozhodně K-nejbližších sousedů.

7.3 Výsledná segmentace


Segmentace v této bakalářské práci byla prováděna pomocí klasifikace pixelů a to pro několik mikroskopických modalit. Principem je vytvoření příznaků, které jsou následně využity pro naučení klasifikátoru, který hledá vztah mezi pixely příznaků a pixely referenčního snímku. Následně má pak za úkol zařadit pixely testovacího snímku do správné třídy, tedy jestli je to pixel buňky (1), nebo pixel pozadí (0). Pro naši práci byly použity čtyři mikroskopické modalities, jejichž výsledky se poměrně liší. Jako nejlepší je, podle statistických výsledků, vyhodnocen snímek QPI, jehož

segmentace je vidět na obrázku 7.1. Nejdůležitější je zde snímek 7.1b, který obsahuje jak segmentovaný snímek, tak kontury vytvořené podle reference. Je možné vidět, že až na pouhé detaily a některé okrajové části buněk je segmentace velmi úspěšná.




Obr. 7.1: Na snímku (a) je vidět segmentace modalit QPI s nejlepšími výsledky. Snímek (b) obsahuje červené kontury vytvořené z referenčního snímku a snímek (c) je původní obraz převdený do formátu double.

U následujících tří mikroskopických modalit už výsledky tak dobré nejsou, o čemž vypovídají také statistické výsledky z podkapitoly 6.3. Jako druhá nejlepší byla vyhodnocena modalita HMC, kterou lze vidět na obrázku 7.2. Následně pak na obrázku 7.3 je vyobrazena modalita DIC, která statisticky zaostává za HMC snímkem o 2,7%. Jelikož ale snímky obsahují velké množství pixelů, tak vzhledově rozdíly nejsou tak markantní.




Obr. 7.2: Na snímku (a) je vidět segmentace modalit HMC s nejlepšími výsledky. Snímek (b) obsahuje červené kontury vytvořené z referenčního snímku a snímek (c) je původní obraz převdený do formátu double.

Jako nejhorší byly vyhodnoceny snímky PC, které dosahovaly maximálně na hodnotu $DSC = 71,30\%$. Jejich segmentace je vyobrazena na obrázku 7.4 Jak si ale




Obr. 7.3: Na snímku (a) je vidět segmentace modalit DIC s nejlepšími výsledky. Snímek (b) obsahuje červené kontury vytvořené z referenčního snímku a snímek (c) je původní obraz převedený do formátu double.

můžete všimnout z obrázku 7.5, vizuální rozdíl opět není tak velký v porovnání se snímky HMC a DIC.



Obr. 7.4: Na snímku (a) je vidět segmentace modalit PC s nejlepšími výsledky. Snímek (b) obsahuje červené kontury vytvořené z referenčního snímku a snímek (c) je původní obraz převedený do formátu double.

Rozdílná úspěšnost segmentace mezi QPI snímky a ostatními modalitami může být způsobena tím, že QPI modalita už v původním snímku vytváří markantní rozdíl, mezi buňkou, která je výrazně světlejší, a pozadím, které je černé. U ostatním druhů snímků takový rozdíl není. Buňky částečně prostorově vystupují, ale odstínem, či barvou se od pozadí liší pouze minimálně.



Obr. 7.5: Na snímku (a) je zobrazena segmentace modality HMC($DSC = 75, 29\%$). Snímek (b) je segmentovaný obraz modality DIC ($DSC = 72, 59\%$) a na snímku (c) je segmentována modalita PC($DSC = 71, 30\%$). Snímky (d),(e) a (f) jsou pak reference k jednotlivým snímkům nad nimi.

Závěr

Tématem této bakalářské práce byla segmentace obrazů pomocí klasifikace pixelů. Jako první byla vytvořena literární řešerše, která se zabývala předzpracováním obrazů, metodami pro výběr vhodné podmnožiny příznaků, následnou klasifikací snímků a také byly zmíněny další metody segmentace.

Praktická část byla naprogramována v prostředí MATLAB. Jejím cílem bylo vytvoření příznaků předzpracováním použitých snímků, výběr vhodných příznaků pro danou mikroskopickou modalitu a dále klasifikace pixelů. Pro vyhodnocení výsledků bylo využito tří statistických metrik a to Dice (DSC), pozitivní prediktivní hodnota (PPH) a senzitivita. Jako rozhodující parametr byl vybrán Dice, jelikož je to parametr, který určuje, jak se segmentovaný obraz podobá referenci, a také protože byl použit při výběru vhodné podmnožiny příznaků. Výběr podmnožiny příznaků byl proveden pomocí metod minimální redundance maximální relevance, neboli mRMR, a metodou dopřednou, která počítala právě s metrikou Dice. Následně byla provedena klasifikace pixelů. Pro klasifikaci bylo využito tří klasifikátorů, které se běžně používají pro tuto problematiku. Jsou to Náhodný les, k-nejbližších sousedů a metoda podpurných vektorů. U těchto klasifikátorů byly měněny parametry za cílem získat co nejlepší výsledky. V podkapitole 6.3 jsou shrnuty a popsány nejlepší dosažené výsledky, podle kterých se dá rozhodnout, že jako lepší metoda pro výběr příznaků je metoda dopředná, která vykazovala lepší výsledky segmentace pro všechny modalit a jako nejefektivnější klasifikátor je zvolen k-nejbližších sousedů, který sice nedosahoval nejlepších statistických výsledků pro všechny modalit, ale díky kombinaci poměrně dobrých výsledků, v porovnání s ostatními klasifikátory, a své nízké časové náročnosti je hodnocen jako nejlepší.

Literatura

- [1] JAN, Jiri. Medical image processing, reconstruction, and restoration: concepts and methods. Boca Raton, FL: Taylor and Francis, 2006. ISBN 0824758498.
- [2] WALEK, P.; LAMOŠ, M.; JAN, J. Analýza biomedicínských obrazů. Analýza biomedicínských obrazů. Brno: 2013. p. 1-138. ISBN: 978-80-214-4792- 9.
- [3] HLAVÁČ, Václav. *Zpracování signálu a obrazu*: Pracovní verze skriptu v tisku pro studenty FEL ČVUT [online]. 1999 [cit. 2019-10-4]. Dostupné z:
<<https://docplayer.cz/7024031-Zpracovanisignalu-a-obrazu-pracovni-verze-skripta-v-tisku-pro-studenty.html>>.
- [4] SONKA, Milan, Vaclav HLAVAC a Roger BOYLE. Image processing, analysis, and machine vision. 3rd ed. Toronto: Thompson Learning, c2008. ISBN 978-0495082521.
- [5] HLAVÁČ, Václav. *Hledání hran*. In: Center for Machine Perception: Czech Technical University in Prague [online]. Praha, 2019 [cit. 2019-10-8]. Dostupné z:
<https://cw.fel.cvut.cz/old/_media/courses/a4m33dzo/22edgedetection_.pdf>.
- [6] HLAVÁČ, Václav. *Předzpracování obrazů v prostorů obrazů, operace v lokálním sousedství*. České vysoké učení technické v Praze [online]. Praha, 2019 [cit. 2019-10-10]. Dostupné z:
<<http://people.ciirc.cvut.cz/~hlavac/TeachPresCz/11DigZpr0br/21ImagPreprocCz.pdf>>.
- [7] FERRARI, Stefano. Image segmentation. Dipartimento di Informatica [online]. Milano, 2011-2012 [cit. 2019-10-10]. Dostupné z:
<http://homes.di.unimi.it/ferrari/ImgProc2011_12/EI2011_12_16_segmentation_double.pdf>.
- [8] ŠPANĚL, M., BERAN, V. Obrazové segmentační techniky. Přehled existujících metod. Vysoké učení technické v Brně [online], FIT, 2006 [cit. 2019-10-12]. Dostupné z:
<<http://www.fit.vutbr.cz/~spanel/segmentace/.en>>.
- [9] KASS, Michael, Andrew WITKIN a Demetri TERZOPOULOS. Snakes: Active contour models. International Journal of Computer Vision [online]. 1988, 1(4),

- 321-331 [cit. 2019-11-29]. DOI: 10.1007/BF00133570. ISSN 0920-5691. Dostupné z:
<<http://link.springer.com/10.1007/BF00133570>>
- [10] THEODORIDIS, Sergios a Konstantinos KOUTROUMBAS. Pattern recognition. 4th ed. Burlington, Mass.: Academic Press, c2009. ISBN 978-1-59749-272-0.
 - [11] NIXON, Mark S. a Alberto S. AGUADO. Feature extraction and image processing for computer vision. 3rd ed. Oxford: Academic Press, 2012. ISBN 978-0-123-96549-3.
 - [12] XIAOOU, Tang. *Texture Information in Run-Length Matrices*. Department of Electrical and Computer Engineering, Democritus University of Thrace. Greece, 1998. [cit. 2019-11-8]. S 1057-7149(98)07752 Dostupné z:
<http://mmlab.ie.cuhk.edu.hk/archive/2000/IP00_Texture.pdf>
 - [13] JIN, Jiaoying, Linjun YANG, Xuming ZHANG a Mingyue DING. Vascular Tree Segmentation in Medical Images Using Hessian-Based Multiscale Filtering and Level Set Method. Computational and Mathematical Methods in Medicine [online]. 2013, 2013, 1-9 [cit. 2019-11-10]. DOI: 10.1155/2013/502013. ISSN 1748-670X. Dostupné z: <<http://www.hindawi.com/journals/cmmm/2013/502013/>>
 - [14] TEKE, Mustafa a Alptekin TEMIZEL. Multi-spectral Satellite Image Registration Using Scale-Restricted SURF. In: 2010 20th International Conference on Pattern Recognition [online]. IEEE, 2010, 2010, s. 2310-2313 [cit. 2019-11-10]. DOI: 10.1109/ICPR.2010.565. ISBN 978-1-4244-7542-1. Dostupné z: <<http://ieeexplore.ieee.org/document/5595974/>>
 - [15] MURPHY, Kevin P. Machine learning: a probabilistic perspective. Cambridge, MA: MIT Press, c2012. ISBN 978-0-262-01802-9.
 - [16] BISHOP, Christopher M. Pattern recognition and machine learning. New York: Springer, c2006. Information science and statistics. ISBN 0-387-31073-8.
 - [17] WATT, Jeremy, Reza BORHANI a Aggelos Konstantinos KATSAGGELOS. Machine learning refined: foundations, algorithms, and applications. New York: Cambridge University Press, 2016. ISBN 978-1-107-12352-6.
 - [18] STORK, David G., Elad YOM-TOV a Richard O. DUDA. Computer manual in MATLAB to accompany Pattern classification, second edition. Hoboken, N.J.: John Wiley, c2004. ISBN 978-0471429777.

- [19] JAHNE, Bernd. Practical handbook on image processing for scientific and technical applications. 2nd ed. Boca Raton [Fla.]: CRC Press, c2004. ISBN 0-8493-1900-5.
- [20] ORŁOWSKI, P. a M. ORKISZ. Efficient computation of Hessian-based enhancement filters for tubular structures in 3D images. IRBM [online]. 2009, 30(3), 128-132 [cit. 2019-11-18]. DOI: 10.1016/j.irbm.2009.04.003. ISSN 19590318. Dostupné z: <<https://linkinghub.elsevier.com/retrieve/pii/S1959031809000487>
- [21] BOVIK, Alan C. Handbook of image and video processing. 2nd ed. Boston, MA: Elsevier Academic Press, 2005. ISBN 978-0-12-119792-6.
- [22] SHRIVAKSHAN, G.T. a C. CHANDRASEKAR. A Comparison of various Edge Detection Techniques used in Image Processing. International Journal of Computer Science Issues. 2012, 2012(9), 269-276 [cit. 2019-11-26] . DOI: 10.1.1.402.1860. ISSN 1694-0814.
- [23] BRUCE, Peter C. a Andrew BRUCE. Practical statistics for data scientists: 50 essential concepts. Sebastopol, CA: O'Reilly, 2017. ISBN 1491952962.
- [24] MEDINA-CARNICER, R., F.J. MADRID-CUEVAS, A. CARMONA-POYATO a R. MUÑOZ-SALINAS. On candidates selection for hysteresis thresholds in edge detection. Pattern Recognition [online]. 2009, 42(7), 1284-1296 [cit. 2020-02-16]. DOI: 10.1016/j.patcog.2008.10.027. ISSN 00313203. Dostupné z: <<https://linkinghub.elsevier.com/retrieve/pii/S0031320308004664>
- [25] RADOVIC, Milos, Mohamed GHALWASH, Nenad FILIPOVIC a Zoran OB-RADOVIC. Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. BMC Bioinformatics [online]. 2017, 18(1) [cit. 2020-04-18]. DOI: 10.1186/s12859-016-1423-9. ISSN 1471-2105. Dostupné z: <<http://bmcbioinformatics.biomedcentral.com/articles/10.1186/s12859-016-1423-9>
- [26] MAO, K.Z. Orthogonal Forward Selection and Backward Elimination Algorithms for Feature Subset Selection. IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics) [online]. 2004, 34(1), 629-634 [cit. 2020-04-18]. DOI: 10.1109/TSMCB.2002.804363. ISSN 1083-4419. Dostupné z: <<http://ieeexplore.ieee.org/document/1262531/>

- [27] DAS, Sanmay. (2001). Filters, Wrappers and a Boosting-Based Hybrid for Feature Selection.. Proceedings of the Eighteenth International Conference on Machine Learning. 74-81. Dostupné z: <<https://pdfs.semanticscholar.org/93b6/25a0e35b59fa6a3e7dc1cbdb31268d62d69f.pdf>
- [28] WOLD, Svante, Kim ESBENSEN a Paul GELADI. Principal component analysis. Chemometrics and Intelligent Laboratory Systems [online]. 1987, 2(1-3), 37-52 [cit. 2020-04-18]. DOI: 10.1016/0169-7439(87)80084-9. ISSN 01697439. Dostupné z: <<https://linkinghub.elsevier.com/retrieve/pii/0169743987800849>
- [29] ABDI, Hervé a Lynne J. WILLIAMS. Principal component analysis. Wiley Interdisciplinary Reviews: Computational Statistics [online]. 2010, 2(4), 433-459 [cit. 2020-04-18]. DOI: 10.1002/wics.101. ISSN 19395108. Dostupné z: <<http://doi.wiley.com/10.1002/wics.101>
- [30] AHONEN, T., A. HADID a M. PIETIKAINEN. Face Description with Local Binary Patterns: Application to Face Recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence [online]. 2006, 28(12), 2037-2041 [cit. 2020-05-19]. DOI: 10.1109/TPAMI.2006.244. ISSN 0162-8828. Dostupné z: <<http://ieeexplore.ieee.org/document/1717463/>
- [31] CHANDRASHEKAR, Girish a Ferat SAHIN. A survey on feature selection methods. Computers and Electrical Engineering [online]. 2014, 40(1), 16-28 [cit. 2020-05-19]. DOI: 10.1016/j.compeleceng.2013.11.024. ISSN 00457906. Dostupné z: <<https://linkinghub.elsevier.com/retrieve/pii/S0045790613003066>
- [32] SILBERMAN, Nathan, David SONTAG a Rob FERGUS. Instance Segmentation of Indoor Scenes Using a Coverage Loss. FLEET, David, Tomas PAJDLA, Bernt SCHIELE a Tinne TUYTELAARS, ed. Computer Vision – ECCV 2014 [online]. Cham: Springer International Publishing, 2014, 2014, s. 616-631 [cit. 2020-05-20]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-10590-1_40. ISBN 978-3-319-10589-5. Dostupné z: <http://link.springer.com/10.1007/978-3-319-10590-1_40
- [33] RAMTEKE, Rakesh and Khachane, Monali. (2012). Automatic Medical Image Classification and Abnormality Detection Using K- Nearest Neighbour. International Journal of Advanced Computer Research. Volume-2 Number-4. 190-196. ISSN 2277-7970. Dostupné z: <https://www.researchgate.net/publication/305403850_Automatic_Medical_Image_Classification_and_Abnormality_Detection_Using_K-_Nearest_Neighbour

Seznam symbolů, veličin a zkratek

D	Trénovací data
DSC	Dice similarity coefficient, F1-skóre
E	Entropie
f	Původní obraz
g	Výsledná obraz
h	Histogram
$I(\mathbf{x};\mathbf{y})$	Vzájemná informace
K	Matice kovariancí
kNN	Klasifikátor K-nejbližších sousedů
mRMR	Metoda minimální redundance a maximální relevance
P	Pravděpodobnost
PPH	Pozitivní prediktivní hodnota RBFKernelovská funkce s radiální bází
SVM	Metoda podpůrných vektorů
t	Větev stromu v náhodném lese

A Další vybrané výsledky

Tabulky A.1, A.2, A.3 a A.4 obsahují výsledky dosažené pro méně vhodné podmnožiny, ale se stejným nastavením klasifikátorů, jako je v podkapitole 6.3. Vždy v horní polovině jsou výsledky pro množinu vybranou metodou dopřednou, v dolní polovině pak pro metodu mRMR. Tabulky A.5, A.6, A.7 a A.8 obsahují, pro ukázkou, výsledky pro další nastavení klasifikátorů.

Tab. A.1: Tabulka shrnuje výsledky horších podmnožin příznaků modality DIC. Horní polovina obsahuje výsledky pro metodu dopřednou, dolní polovina výsledky pro metodu mRMR.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
8,9,10,1,3,5						
DSC [%]	71,51	71,96	72,17	72,27	22,81	71,51
Senzitivita [%]	71,61	72,22	71,14	71,08	22,12	65,12
PPH [%]	72,75	72,91	74,61	74,90	21,01	79,91
6,11,10,5,12,9						
DSC [%]	71,16	71,29	70,79	71,02	21,82	70,28
Senzitivita [%]	70,80	70,81	70,71	70,96	20,65	65,21
PPH [%]	72,96	72,89	72,31	72,51	21,60	76,81

Tab. A.2: Tabulka shrnuje výsledky horších podmnožin příznaků modalit HMC. Horní polovina obsahuje výsledky pro metodu dopřednou, dolní polovina výsledky pro metodu mRMR.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
9,8,6,4,1,5						
DSC [%]	73,33	73,53	74,60	74,87	24,73	73,67
Senzitivita [%]	74,61	73,97	75,85	76,25	23,49	69,89
PPH [%]	72,62	72,90	73,84	73,97	22,37	76,42
9,11,10,5,12,3						
DSC [%]	71,97	71,53	71,51	71,72	23,01	72,23
Senzitivita [%]	70,57	69,97	70,45	70,64	22,71	65,81
PPH [%]	74,03	73,90	73,26	73,50	21,57	75,92

Tab. A.3: Tabulka shrnuje výsledky horších podmnožin příznaků modalit QPI. Horní polovina obsahuje výsledky pro metodu dopřednou, dolní polovina výsledky pro metodu mRMR.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
5,3,2,1,7,8						
DSC [%]	92,28	91,31	92,21	92,22	42,46	91,87
Senzitivita [%]	93,65	92,51	92,70	92,75	60,02	93,58
PPH [%]	91,01	90,24	91,79	91,86	54,68	90,29
8,5,12,10,11,3						
DSC [%]	91,62	90,57	92,07	92,09	43,68	91,07
Senzitivita [%]	91,71	90,13	93,14	92,24	58,92	92,14
PPH [%]	91,60	90,67	91,67	92,01	53,91	90,38

Tab. A.4: Tabulka shrnuje výsledky horších podmnožin příznaků modalitu PC. Horní polovina obsahuje výsledky pro metodu dopřednou, dolní polovina výsledky pro metodu mRMR.

Podmnožina příznaků:	Náhodný les		K-nejbližších sousedů		SVM	
	100 stromů	200 stromů	k=25	k=35	Polynomiální kernel	RBF kernel
7,5,11,10,12,3						
DSC [%]	62,33	62,29	63,31	63,30	19,98	58,99
Senzitivita [%]	53,21	53,07	57,13	56,51	19,83	48,65
PPH [%]	75,85	76,02	71,60	72,57	18,27	75,76
9,7,8,4,2,3						
DSC [%]	69,73	70,22	65,67	65,78	21,61	64,15
Senzitivita [%]	66,73	67,11	61,64	61,77	20,92	56,82
PPH [%]	73,55	73,48	70,75	70,83	20,91	74,43

Tab. A.5: Tato tabulka shrnuje výsledky dalšího nastavení klasifikátorů K-nejbližších sousedů a Náhodného lesa pro modalitu DIC. V horní polovině je nastavení pro podmnožinu vytvořenou dopřednou metodou, v dolní pro mRMR.

Podmnožina příznaků	K-nejbližších sousedů			Náhodný les
	k=5	k=15	k=30	
8,7,10,9,11,2				50 stromů
DSC [%]	69,56	71,91	72,35	71,64
Senzitivita [%]	71,18	73,51	73,51	72,89
PPH [%]	69,24	71,54	72,37	71,24
8,11,10,5,12,6				
DSC [%]	68,88	71,77	71,67	70,92
Senzitivita [%]	69,69	73,00	72,20	70,13
PPH [%]	69,84	72,25	72,88	72,29

Tab. A.6: Tato tabulka shrnuje výsledky dalšího nastavení klasifikátorů K-nejbližších sousedů a Náhodného lesa pro modalitu HMC. V horní polovině je nastavení pro podmnožinu vytvořenou dopřednou metodou, v dolní pro mRMR.

Podmnožina příznaků	K-nejbližších sousedů			Náhodný les
9,6,7,8,4,2	k=5	k=15	k=30	50 stromů
DSC [%]	71,78	74,09	74,78	71,28
Senzitivita [%]	72,60	75,16	76,48	72,88
PPH [%]	71,44	73,15	73,64	72,71
8,10,11,5,12,3				
DSC [%]	68,16	70,53	71,09	70,92
Senzitivita [%]	66,59	70,05	69,24	69,87
PPH [%]	70,68	73,76	73,70	72,11

Tab. A.7: Tato tabulka shrnuje výsledky dalšího nastavení metody podpurných vektorů pro modalitu QPI. V horní polovině je nastavení pro podmnožinu vytvořenou dopřednou metodou, v dolní pro mRMR.

Podmnožina příznaků	Polynomiální kernel			RBF kernel		
5,3,2,1,9,6	5.stupeň BC=5	5.stupeň BC=100	2.stupeň BC=100	$\gamma=10$ BC=5	$\gamma=10$ BC=100	$\gamma=0,5$ BC=100
DSC [%]	29,74	31,18	44,59	91,67	91,65	91,69
Senzitivita [%]	64,80	63,29	60,32	92,70	92,71	92,70
PPH [%]	12,28	13,48	54,91	90,72	90,67	90,73
2,5,11,10,12,7						
DSC [%]	28,81	29,14	42,61	91,07	91,02	91,09
Senzitivita [%]	64,13	64,31	61,22	92,14	91,99	92,04
PPH [%]	11,87	12,13	52,77	90,38	90,29	90,48

Tab. A.8: Tato tabulka shrnuje výsledky dalšího nastavení metody podpůrných vektorů pro modalitu PC. V horní polovině je nastavení pro podmnožinu vytvořenou dopřednou metodou, v dolní pro mRMR.

Podmnožina příznaků	Polynomiální kernel			RBF kernel		
	5.stupeň BC=5	5.stupeň BC=100	2.stupeň BC=100	$\gamma=10$ BC=5	$\gamma=10$ BC=100	$\gamma=0,5$ BC=100
7,8,4,1,3,10						
DSC [%]	16,70	16,63	23,38	64,03	64,00	64,15
Senzitivita [%]	27,17	27,20	22,90	56,62	56,54	56,58
PPH [%]	12,06	12,19	21,88	75,12	75,14	74,43
9,5,10,11,12,3						
DSC [%]	15,82	15,81	22,19	58,99	59,02	59,14
Senzitivita [%]	28,01	28,07	22,65	48,65	48,64	48,72
PPH [%]	11,86	11,89	21,69	75,76	75,74	75,69